

**Simulationsbasierte Optimierung
einer agentenbasierten Simulation
mit Anwendungen zur Preisoptimierung im Mobilfunk**

Dissertation

zur Erlangung des Doktorgrades an der
Wirtschaftswissenschaftlichen Fakultät
der Universität Augsburg

vorgelegt von

Andreas Deckert

2012

Erstgutachter:	Prof. Dr. Robert Klein
Zweitgutachter:	Prof. Dr. Axel Tuma
Vorsitzender der mündlichen Prüfung:	Prof. Dr. Michael Krapp
Datum der mündlichen Prüfung:	25. Mai 2012

Inhaltsverzeichnis

1.	Einleitung.....	5
1.1.	Forschungsgegenstand.....	6
1.2.	Forschungsziel und -fragen	7
1.3.	Aufbau der Arbeit.....	8
2.	Preisgestaltung im Mobilfunk	10
2.1.	Beschreibung des Mobilfunkmarktes.....	10
2.1.1.	Anbieter	11
2.1.2.	Tarife	17
2.1.3.	Nutzungs- und Tarifwahlverhalten der Kunden	20
2.1.4.	Besonderheit im Markt: Netzwerkeffekte.....	27
2.2.	Strategien und Steuerungsmechanismen der Preisgestaltung im Mobilfunk.....	29
2.3.	Ziele und Mechanismen der Preisoptimierung	31
2.4.	Bisherige Ansätze zur Preisoptimierung in der Telekommunikation.....	32
2.4.1.	Klassische Optimierungsansätze	33
2.4.2.	Simulationsbasierte Ansätze.....	34
2.4.3.	Abgrenzung der vorliegenden Arbeit.....	35
3.	Grundlagen und Anwendungen der agentenbasierten Simulation.....	37
3.1.	Agentenbasierte Simulation.....	37
3.1.1.	Einordnung und Abgrenzung zu klassischen simulationsbasierten Ansätzen	38
3.1.2.	Agenten und deren Verhalten.....	40
3.1.3.	Eignung und Anwendungsfelder	42
3.2.	Beispiele betriebswirtschaftlicher Anwendungen.....	43
3.2.1.	Systematik der Klassifikation	44
3.2.2.	Praxisbeispiele betriebswirtschaftlicher Anwendungen	44
3.2.3.	Beurteilung der Praxisanwendungen.....	57
3.3.	Anwendungsprozess	58
3.3.1.	Problemanalyse und -spezifikation	59
3.3.2.	Modellierung.....	59
3.3.3.	Implementierung und Test	63
3.3.4.	Parametrisierung und Ablauf der Simulation	65
3.3.5.	Analyse und Aufbereitung der Ergebnisse	66
3.4.	Zusammenfassung und Ausblick	66
4.	Agentenbasierte Modellierung und Simulation eines Mobilfunkmarktes.....	67

4.1.	Simulationsmodell und -komponenten	67
4.2.	Modellierung der Anbieter und Tarife.....	70
4.3.	Modellierung der Kunden	72
4.3.1.	Entscheidungsmodell der Agenten	73
4.3.2.	Netzwerk der sozialen Interaktion	78
4.3.3.	Nachfrage- und Präferenzstruktur der Agenten	80
4.4.	Simulationsablauf und -visualisierung	81
4.5.	Prototypische Parametrisierung des Simulationsmodells.....	85
4.6.	Implementierung des Prototyps in der Simulationsumgebung AnyLogic.....	90
4.7.	Diskussion, Anwendung und mögliche Erweiterung	92
5.	Grundlagen der simulationsbasierten Optimierung	95
5.1.	Betrachtetes Grundproblem.....	96
5.1.1.	Allokation von Replikationen.....	98
5.1.2.	Sequenzielle Optimierung	100
5.2.	Anwendungsbezogene Einordnung von Standardansätzen	107
5.2.1.	Optimierung auf Ersatzmodellen	110
5.2.2.	Optimierung mit Gradientenverfahren.....	111
5.2.3.	Optimierung mit Metaheuristiken.....	113
5.2.4.	Optimierung durch zufällige Suche	116
5.2.5.	Industrielösungen zur Optimierung	116
6.	Simulationsbasierte Optimierung der Parameter einer agentenbasierten Simulation...118	
6.1.	Spezielle Problemstellung im Kontext einer agentenbasierten Simulation	119
6.2.	Ausgewählte Verfahren.....	123
6.2.1.	Global Random Search (GRS).....	125
6.2.2.	OptQuest	127
6.2.3.	Simultaneous Perturbation Stochastic Approximation (SPSA)	128
6.2.4.	Evolutionärer Algorithmus NELS	133
6.2.5.	Hybridalgorithmus aus NELS und SPSA	138
6.3.	Demonstration der Verfahren	141
7.	Experimenteller Vergleich der Verfahren zur simulationsbasierten Optimierung	145
7.1.	Versuchsaufbau	145
7.2.	Typische Optimierungsverläufe.....	150
7.3.	Vergleichskriterien und -maßstäbe.....	152
7.4.	Vergleichsdurchführung und -ergebnisse.....	153
7.5.	Ausblick auf weitere Effizienzsteigerung.....	159
8.	Experimentelle Fallstudien.....	163
8.1.	Fallstudie zur Simulation	164

8.2.	Fallstudien zur Optimierung.....	168
8.2.1.	Einfacher Fall ohne Konkurrenzreaktionen	169
8.2.2.	Iterative Optimierung mit Konkurrenzreaktionen.....	171
8.2.3.	Parallele Optimierung mit Konkurrenzreaktionen	174
8.3.	Diskussion der Fallstudien	177
9.	Schlussbetrachtung.....	179
9.1.	Ansatz und Methodik.....	179
9.2.	Implikationen für die Anbieter im Mobilfunkmarkt	181
9.3.	Ausblick für weitere Forschung.....	182
10.	Literaturverzeichnis.....	184

1. Einleitung

Anbieter von Waren oder Dienstleistungen treffen Preisentscheidungen üblicherweise auf Basis einfacher Annahmen über lineare oder zumindest funktional beschreibbare Zusammenhänge zwischen den verlangten Preisen und dem resultierenden Umsatz. Preis-Absatz-Funktionen (vgl. [Homburg und Krohmer 2009], Kap. 12.2.1.2, oder [Simon und Fassnacht 2006], Kap. 3.3), die den mit einem festgelegten Preis erzielbaren Umsatz beschreiben, sind ein gebräuchliches Modell für diese rein nachfrageorientierte Preisbestimmung. Dieser Ansatz unterstellt implizit ein aggregierbares (d. h. strukturell homogenes) und eigenständiges (d. h. von anderen isoliertes) Entscheidungsverhalten der Kunden.

Auf verschiedenen Märkten findet man konträr zu dieser allgemeinen Annahme jedoch ein *heterogenes und gegenseitig bedingtes Entscheidungsverhalten* einer Vielzahl von Kunden im Rahmen ihrer Konsumentenentscheidungen, das zu quasi-chaotischen Wirkungszusammenhängen führen kann. Auf der aggregierten Ebene des Gesamtmarktes (der sog. Makroebene) beobachtbare Zusammenhänge und Entwicklungen ergeben sich damit nur indirekt aus den voneinander abhängenden individuellen Handlungen der einzelnen Kunden (auf der sog. Mikroebene). Dieses Phänomen ist in der wissenschaftlichen Literatur als Emergenz bekannt (vgl. [Epstein 1999]). Dabei ist es in der Regel nicht möglich, einen funktionalen Zusammenhang zwischen der Entwicklung des Marktes und den Entscheidungen und Handlungen der einzelnen Kunden zu ermitteln.

Diese Charakteristika sind besonders ausgeprägt auf dem Markt für Mobilfunkprodukte, weshalb sich die vorliegende Arbeit im Folgenden auf diesen Markt als prototypischen Anwendungsfall konzentriert. Als Anbieter fungieren hier die Mobilfunk-Netzbetreiber, die ihren Kunden Mobiltelefonie als Produkt anbieten. Die Kunden zeigen ein heterogenes Entscheidungsverhalten, da verschiedene Kunden unterschiedliche Aspekte in ihre Entscheidung für einen bestimmten Tarif mit einbeziehen und diese Einflussfaktoren auch unterschiedlich gewichten. Netzwerkeffekte aufgrund des gegenseitig bedingten und damit ebenfalls heterogenen Entscheidungsverhaltens entstehen dabei durch die indirekte oder direkte Präferenz für den Kauf eines in der Umgebung (z. B. in der Nachbarschaft, im Freundes- oder Familienkreis) des Kunden verbreiteten Tarifs (vgl. [Katz und Shapiro 1985]). Indirekt entsteht eine solche Präferenz durch einen eher abstrakten Nutzen, z. B., um jemanden bei Problemen um Rat fragen zu können oder um logistische bzw. organisatorische Synergieeffekte zu heben. Eine direkte Präferenz ergibt sich aus einem konkreten monetären Nutzen, der z. B. durch Volumenrabatte beim Einkauf oder durch sog. Community-Mobilfunktarife entsteht, bei denen Mobiltelefonate innerhalb des Netzes des Anbieters oder zu festen Rufnummern rabattiert sind. Aus dieser Gemengelage können sich emergente Effekte aufschaukeln, die sich bei einer Betrachtung des Marktes von außen jedoch nur schwerlich isolieren und von sonstigen Effekten trennen lassen. Eine konkrete unerwartete Marktentwicklung kann sowohl durch komplexe Wirkungsketten induziert sein als auch einfachere Auslöser haben, die aber nicht in der Marktanalyse betrachtet wurden. Dass es sich bei dem Mobilfunkmarkt um ein komplexes System handelt, hat sich nicht zuletzt plakativ am Beispiel der Einführung der UMTS-Netzwerktechnik gezeigt: Die damals

veröffentlichten Nutzungs- und Gewinnprognosen hatten letztendlich vor allem die Gemeinsamkeit, dass sie um Größenordnungen zu optimistisch waren.

1.1. Forschungsgegenstand

Um die Auswirkungen von Preisentscheidungen der Anbieter auf solchen Märkten a priori besser einschätzen zu können, müssen genau die dargestellten komplexen Marktzusammenhänge berücksichtigt werden. Nur so können beispielsweise fundierte Aussagen zum Zusammenhang zwischen den verlangten Preisen und damit erzielbaren Umsätzen getroffen werden. Hierfür ist die Entwicklung eines Modells des realen Marktsystems notwendig, das diese relevanten Systemcharakteristika adäquat abbildet. Mit einem solchen Modell kann das Systemverhalten im Rahmen einer Simulation analysiert werden. So können z. B. die Auswirkungen verschiedener Annahmen über das Entscheidungsverhalten der Kunden als Modellszenarien durchgespielt werden, um deren Entscheidungsgrundlage besser zu verstehen und so zielgerichtet bepreiste Angebote unterbreiten zu können. Die Simulation stellt also ein Mittel dar, um eine über ein reines Ausprobieren hinausgehende Strategie der Preisgestaltung in Märkten mit Netzwerkeffekten anzuwenden.

Klassische Simulationsansätze, die etwa auf der Modellierung des makroskopischen Systemverhaltens durch (Differenzial-)Gleichungen beruhen, scheitern bei der Analyse solcher Märkte. Stattdessen ist es erforderlich, das individuelle Verhalten der einzelnen Akteure zu modellieren, um deren Entscheidungsprozesse und die daraus resultierenden Handlungen simulieren zu können und zu treffenden Aussagen über die Entwicklung des Gesamtsystems zu gelangen. In den vergangenen Jahren hat sich zu diesem Zweck die agentenbasierte Simulation (ABS) als ein Werkzeug etabliert (vgl. [Bonabeau 2007]). Hierbei werden die Kunden im Markt als sogenannte Agenten in einem Simulationsmodell abgebildet und die Entwicklung des Systems, das sich durch Handlungen der Kunden (Agenten) sowie durch ihre dynamische Interaktion ergibt, in der darauf aufbauenden Simulation untersucht. Die ABS stellt hierbei eine Art virtuelles Labor der experimentellen Wirtschaftsforschung dar (vgl. [Epstein und Axtell 1996], S. 52). Mit einer solchen Simulation eröffnet sich eine vielversprechende Möglichkeit, das Verhalten des komplexen Mobilfunkmarktes in Reaktion auf Preisentscheidungen der Anbieter im Modell zu erforschen und für den Anbieter gute Preisentscheidungen zu identifizieren. Auf dieser Basis können Erkenntnisse zu möglichen Strategien der Preisgestaltung im realen Markt abgeleitet werden.

Die simulationsbasierte Optimierung (SBO) stellt den strukturierten, wissenschaftlichen Ansatz zu der weitergehenden Frage dar, wie nicht nur gute, sondern optimale Preisentscheidungen in einem solchen Modell identifiziert werden können. Bei der SBO werden die Parameter einer Simulation (z. B. die im Rahmen dieser Arbeit betrachteten Preise des Tarifportfolios eines Mobilfunkanbieters) zwischen aufeinanderfolgenden Simulationsläufen variiert mit dem Ziel, eine optimale Konfiguration der Parameter zu ermitteln. Erschwert wird dies durch den stochastischen Charakter der Simulation, der dazu führt, dass unterschiedliche Simulationsläufe mit einer identischen Parameterkonfiguration trotzdem zu unterschiedlichen Ergebnissen führen können, was eine rechenintensive Mehrfachauswertung notwendig macht. Genau für den Umgang mit dieser Problematik bietet die SBO geeignete Optimierungsalgorithmen. Zwar haben diese Verfahren in der wissenschaftlichen

Forschung des vergangenen Jahrzehnts parallel zum vermehrten Aufkommen stochastischer Modelle zunehmend Verbreitung gefunden, deren spezifische Anwendung auf eine ABS stellt bisher aber ein kaum beachtetes Forschungsfeld dar.

Bei einer umfassenden Reflexion der Literatur zur ABS (vgl. Kap. 3) fällt schnell auf, dass ein Großteil der bis dato existierenden Publikationen Problemstellungen mit eher geringem praktischen Anwendungspotenzial diskutiert oder auf (zumindest aus betriebswirtschaftlicher Sicht) völlig abstrakter Ebene verbleibt. Dieser Zustand dokumentiert, dass auch die wissenschaftliche Gemeinde noch weit davon entfernt ist, die ABS als ein Standardwerkzeug für bestimmte Anwendungsfälle anzusehen. Die vorliegende Arbeit soll einen Beitrag dazu leisten, dies zu ändern und die ABS sowohl als ein Werkzeug der betriebswirtschaftlichen Forschung zu etablieren wie auch Anwendungen im unternehmerischen Alltag aufzuzeigen. Da sich betriebswirtschaftliche Fragestellungen selten nur mit der reinen Analyse einer Problemstellung befassen, sondern in der Regel darauf abzielen, Stoßrichtungen für aus wirtschaftlicher Sicht optimale Entscheidungen oder sogar konkrete operative Handlungsempfehlungen zu identifizieren, stellt die Anwendung von Verfahren der SBO den folgerichtigen Schritt zur weiteren Evolution dieser Methodik auf dem Weg zu einem kompletten und praxistauglichen Werkzeug dar.

Die Praxisrelevanz des hier betrachteten Themas lässt sich gut mit folgendem aktuellen Zitat von Teltarif¹, einem Branchennewsletter der Telekommunikation, illustrieren:

„Vor kurzem hat E-Plus sein Base-Angebot komplett überarbeitet. Was als Tarif-Revolution angekündigt wurde, rief aber schnell Kritik auf den Plan: Ein Manko war die neue Trennung von Base- und sonstigen E-Plus-Anschlüssen im Tarifschema, so dass sowohl die Inklusivminuten im Basis-Tarif als auch die Intern-Flatrate eben keine Anrufe mehr zu anderen Kunden im E-Plus-Netz abseits Base abdeckte.“

Es zeigt sich, dass auch die Fachpresse bessere Einblicke in die Wirkungsmechanismen des komplexen Mobilfunkmarktes als hochrelevant einstuft. Vielleicht wäre E-Plus besser beraten gewesen, vor der beschriebenen Tarifänderung die Konsequenzen eingehender auszuloten. Eine optimale Preisentscheidung scheint das Unternehmen nach dem Urteil der Presse zumindest nicht gefunden zu haben.

1.2. Forschungsziel und -fragen

Ziel der vorliegenden Arbeit ist die Modellierung eines Mobilfunkmarktes als ABS und die Identifikation und Verprobung geeigneter Methoden der SBO, um die Parameter der ABS hinsichtlich einer ökonomischen Zielsetzung zu optimieren. Mit den hierzu entwickelten und vorgestellten Werkzeugen wird die Entscheidungsunterstützung eines Mobilfunkanbieters bei dessen taktischer Preis- und damit Tarifgestaltung ermöglicht, was an proto-

¹ <http://www.teltarif.de/nl/n561.html#mobilfunk>, abgerufen am 18. Februar 2010.

typischen Fallstudien exemplarisch gezeigt wird. Die Simulation des Mobilfunkmarktes an sich ermöglicht hierbei ein besseres Verständnis der Kräfte, die auf diesem Markt mit Netzwerkeffekten wirken, z. B. zur Identifikation stabiler Marktsituationen oder von Schwellen, an denen die Entwicklung der Simulation signifikant unterschiedliche Verläufe nimmt. Durch die darauf aufgesetzte Optimierung bietet sich die Möglichkeit, die Simulation nicht nur qualitativ zu untersuchen, sondern optimale quantitative Werte für Entscheidungsvariablen algorithmisch herzuleiten, die freie Parameter einer Simulation abbilden.

Zu diesem Zweck gilt es, verschiedene zentrale Forschungsfragen zu klären, die bisher in der wissenschaftlichen Literatur nur wenig Beachtung gefunden haben oder nicht in dem für die vorliegende Arbeit relevanten Kontext betrachtet wurden:

- (1) Wie lässt sich ein Mobilfunkmarkt mit Anbietern und Kunden in einem agentenbasierten Simulationsmodell problemadäquat abbilden? Wie lassen sich hierbei insbesondere im Kontext individueller Heterogenität und gegenseitig bedingten Entscheidungsverhaltens die Entscheidungen der Kunden modellieren?
- (2) Wie lässt sich eine Optimierung der freien Parameter der ABS nach einem aus dem Ablauf der der Simulation berechneten Zielkriterium algorithmisch durchführen? Welche Ansätze eignen sich besonders für die charakteristische Problemstellung einer ABS?
- (3) Welche Schlüsse bezüglich der Preisgestaltung auf dem realen Markt lassen sich für Mobilfunkanbieter aus der Optimierung einer solchen ABS ziehen?

1.3. Aufbau der Arbeit

Um die gezeigten zentralen Forschungsfragen fundiert und umfassend beantworten zu können, wird im Rahmen dieser Arbeit zunächst in Kapitel 2 ein Überblick des hier beispielhaft betrachteten Mobilfunkmarktes gegeben, und es werden typische Entscheidungsprobleme der Anbieter im Rahmen der Preisgestaltung identifiziert. In Kapitel 3 schließt sich eine Einführung in das Werkzeug der agentenbasierten Simulation an, unterstützt durch einen umfassenden Überblick der publizierten Literatur zur Analyse und Lösung betriebswirtschaftlicher Entscheidungsprobleme mithilfe einer ABS. Angelehnt an das Beispiel des deutschen Mobilfunkmarktes wird in Kapitel 4 ein agentenbasiertes Modell des Mobilfunkmarktes entwickelt und in der Simulationsumgebung AnyLogic² implementiert. Den inhaltlich zweiten Kernbereich dieser Arbeit stellt die simulationsbasierte Optimierung dar. Kapitel 5 dient hierzu als eine breite Übersicht des aktuellen Forschungsstands zur SBO. Insbesondere wird darauf eingegangen, welche Verfahren sich für Problemstellungen im Rahmen einer ABS eignen. In Kapitel 6 wird die Funktionsweise einiger hierfür zentraler Standardansätze wie auch eigenentwickelter Optimierungsverfahren zur SBO im Detail vorgestellt. Deren Leistungsfähigkeit und konkrete Eignung für die Optimierung der Parameter

² Ein Produkt der Firma XJ Technologies, siehe <http://www.xjtek.com>, abgerufen am 15. Dezember 2010.

einer ABS wird in Kapitel 7 sowohl anhand theoretischer Überlegungen als auch anhand einer Verprobung im Kontext der beschriebenen ABS des Mobilfunkmarktes verglichen. In Kapitel 8 werden experimentelle Fallstudien präsentiert, die mögliche Anwendungsszenarien für eine Entscheidungsunterstützung durch die vorgestellten Optimierungsverfahren darstellen. Abschließend werden in Kapitel 9 die im Rahmen dieser Arbeit gesammelten Erkenntnisse aufgegriffen und zur Beantwortung der initial aufgeworfenen zentralen Forschungsfragen verwendet.

Diese Arbeit umfasst somit ein Querschnittsthema, das die vier wissenschaftlichen Domänen der Modellierung, der Simulation, der Optimierung und der Analyse beinhaltet. Zur Übersicht werden in Abbildung 1 die Kapitel entlang dieser Fachgebiete eingeordnet:

	Modellierung	Simulation	Optimierung	Analyse
Kapitel 2	Preisgestaltung im Mobilfunk			
Kapitel 3	Grundlagen und Anwendungen der ABS			
Kapitel 4	Agentenbasierte Modellierung und Simulation des Mobilfunkmarktes			
Kapitel 5			Grundlagen der SBO	
Kapitel 6		SBO der Parameter einer ABS		
Kapitel 7		Experimenteller Vergleich der Verfahren zur SBO		
Kapitel 8		Experimentelle Fallstudien		
Kapitel 9	Schlussbetrachtung			

Abbildung 1: Einordnung der Kapitel dieser Arbeit

Quelle: eigene Darstellung

2. Preisgestaltung im Mobilfunk

Um die Entscheidungsprobleme eines Mobilfunk-Netzbetreibers bei dessen Preisgestaltung transparent zu machen, bietet das folgende Kapitel eine Einführung in die typischen Charakteristika eines Mobilfunkmarktes am Beispiel Deutschland. Dies umfasst die grundlegende Übersicht des Marktes anhand verschiedener statistischer Kenndaten sowie anhand einer näheren Analyse der Anbieter (vgl. Kap. 2.1.1), der Tarife (vgl. Kap. 2.1.2) und der Kunden (vgl. Kap. 2.1.3). Darauf aufbauend befasst sich Kapitel 2.1.4 mit den für die vorliegende Arbeit bedeutsamen Netzwerkeffekten im Mobilfunkmarkt. Anschließend folgen eine Analyse des Problems der Preisgestaltung im Mobilfunk (vgl. Kap. 2.2) sowie eine Diskussion bisher existierender Ansätze aus der wissenschaftlichen Literatur (vgl. Kap. 2.4). Die Marktmodellierung in Kapitel 4 und die Fallstudien in Kapitel 8 greifen an verschiedenen Stellen auf die im Folgenden aufgezeigten Daten und Zusammenhänge zurück, um eine Fundierung des dort gezeigten Entscheidungsproblems anhand des deutschen Mobilfunkmarktes herzustellen.

Eine Beschreibung der Entwicklung des Mobilfunkmarktes aus technischer Sicht mit den relevanten technischen Grundlagen und Standards steht nicht im Fokus dieser Arbeit, findet sich aber sehr ausführlich in [Gruber 2005] (Kap. 2.2 und 2.3). Ebenfalls findet keine Auseinandersetzung mit der frühen wirtschaftlichen Entwicklung des deutschen Mobilfunkmarktes statt, diese wird in [Gruber 2005] (Kap. 3.4.7) detailliert beschrieben. Beide Aspekte werden ebenfalls bei [Gans et al. 2005] eingehend behandelt.

2.1. Beschreibung des Mobilfunkmarktes

Der Mobilfunkmarkt grenzt sich von dem anderen großen Bereich der Telekommunikation, dem Festnetzmarkt, unter anderem durch die Anbieterstruktur, die etablierten Produkte und Geschäftsmodelle sowie durch die Kundennachfrage ab. Abbildung 2 zeigt einen Vergleich der Kenndaten dieser beiden Märkte für Deutschland. Charakteristisch und auffallend ist hierbei, dass der Mobilfunk das Festnetz nach der Zahl der Anschlüsse weit überflügelt hat, aufgrund einer deutlich geringeren Nutzung aber nicht an dessen Umsätze heranreicht.




Abbildung 2: Vergleich Mobilfunk vs. Festnetz in Deutschland

Quelle: eigene Darstellung, [Bundesnetzagentur 2008] (S. 66), [Dialog Consult/VATM 2009] (S. 5 und 21)

Der Mobilfunkmarkt umfasst Mobilfunkdienste wie Sprach- und Datenkommunikation sowie darauf aufbauende Mehrwertdienste. All diese Dienste werden per Funk über dedizierte Mobilfunknetze nach entsprechenden Standards wie GSM oder UMTS und auf dafür von staatlichen Regulierungsbehörden lizenzierten Frequenzen übertragen. Die bedeutendsten Mobilfunkdienste sind die Sprachtelefonie (im Fachjargon VOICE genannt), das Senden und Empfangen von SMS- bzw. MMS-Nachrichten (MESSAGE) sowie die Übertragung von Daten (DATA). Abbildung 3 zeigt die Entwicklung der im deutschen Mobilfunkmarkt erzielten Umsätze (ohne Berücksichtigung von Infrastruktur und Endgeräten) sowie die anteilige Bedeutung der genannten Segmente. Im Folgenden konzentriert sich die vorliegende Arbeit auf die Sprachtelefonie, die für sich genommen bereits einen Anteil von etwa drei Viertel des Marktes abdeckt.




Abbildung 3: Umsätze im Mobilfunk (in Mrd. €)

Quelle: eigene Darstellung, [Dialog Consult/VATM 2009] (S. 5 und 24), [Dialog Consult/VATM 2005] (S. 25)

2.1.1. Anbieter

In Deutschland teilen sich vier Betreiber von Mobilfunknetzen („mobile network operator“, MNO) den Markt auf: T-Mobile³, Vodafone⁴, E-Plus⁵ und O₂⁶. Über deren Netze der zweiten und dritten Generation (sog. 2G und 3G) werden sowohl Sprach- als auch Messaging- und Datendienste abgewickelt. T-Mobile (D1-Netz) als Tochter des ehemaligen Staatsmonopolisten Deutsche Telekom eröffnete im Jahr 1992 diesen Markt als Nachfolger des analogen Mobilfunknetzes praktisch zeitgleich mit Mannesmann (D2-Netz), welches später dann als deutsche Landesgesellschaft in den britischen Mobilfunkkonzern Vodafone eingegliedert wurde. Das so entstandene Oligopol wurde im Jahr 1994 durch den neuen Wettbewerber E-Plus (E1-Netz) aufgebrochen, an dem die Industriekonzerne VEBA, RWE und

³ <http://www.t-mobile.de/>, abgerufen am 9. Februar 2010.

⁴ <http://www.vodafone.de/>, abgerufen am 9. Februar 2010.

⁵ <http://www.eplus.de/>, abgerufen am 9. Februar 2010.

⁶ <http://www.o2online.de/>, abgerufen am 9. Februar 2010.

Thyssen beteiligt waren. Im Jahr 1998 kam dann noch der Netzbetreiber O₂ (E2-Netz) als ein Joint Venture der British Telecom und des Industriekonzerns Viag hinzu. Die ursprünglichen Branchen der an der Entstehung des Mobilfunkmarktes beteiligten Unternehmen zeigen, dass hier neben den staatlichen Telekommunikationsunternehmen auch die klassische Industrie ein aussichtsreiches Geschäftsfeld identifiziert hatte. Als zeitweise fünfter Anbieter startete Quam, eine Tochter der finnischen Sonera und der spanischen Telefónica, im Jahr 2001 mit einem eigenen UMTS-Netz, konnte sich jedoch nicht am Markt etablieren und ging bereits 2002 insolvent (vgl. [TeleGeography 2010]).

Über die Jahre haben sich die vier verbliebenen Netzbetreiber mit teilweise stürmischem Wachstum entwickelt, wobei sich der Zeitpunkt des Markteintrittes eines MNOs auch determinierend auf dessen später erzielten Marktanteil ausgewirkt hat (vgl. Abbildung 4). Dies spricht nicht zuletzt auch für die starke Wirksamkeit der bereits erwähnten und später in Kapitel 2.1.4 im Detail diskutierten Netzwerkeffekte im Mobilfunkmarkt.




Abbildung 4: Mobilfunkanschlüsse nach Netzbetreibern

Quelle: eigene Darstellung; Bundesnetzagentur, <http://www.bundesnetzagentur.de>, abgerufen am 19. März 2010

Wie Abbildung 5 zeigt, ist die Nachfrage nach Mobilfunk-Sprachtelefonie in Deutschland im Laufe der Marktentwicklung stetig gestiegen. Beim Kundenstamm von O₂ ist diese traditionell deutlich höher als bei anderen Anbietern, da zentrale Angebote wie die später näher vorgestellten Homezone-Tarife eine intensivere Nutzung stimulierten. Ebenso führen die in großem Umfang innerhalb der letzten Jahre positionierten Pauschalangebote der E-Plus-Tochtermarken zu einer vergleichsweise hohen Nutzung im Netz von E-Plus. T-Mobile als anderes Extremum verzichtete dagegen lange Zeit weitgehend auf eine Nachfragestimulation durch Preis- und Tarifikationen und konnte dadurch einen hohen Umsatz pro Gesprächsminute konservieren. Auffallend ist jedoch, dass sich der durchschnittliche Kundenumsatz (ARPU, „average return per user“) der einzelnen Netzanbieter trotz sehr unterschiedlicher Angebotsgestaltung, unterschiedlicher Kundenstruktur und unterschiedlicher Kundenzugangsstrategie in der aggregierten Sicht stark angenähert hat.




Abbildung 5: Sprachtelefonie-Minuten, Umsatz und ARPU

Quelle: eigene Darstellung; [Merrill Lynch 2009]

Die Kostenstruktur eines MNO besteht hauptsächlich aus quasi-fixen Kosten für den Netzaufbau sowie für die Betriebslizenz. Weitgehend ebenfalls nutzungsunabhängige laufende Kosten entstehen im Marketing, bei der Kundenakquisition (durch Endgerätesubventionen oder Kundenwerbeprämien) sowie bei der Rechnungsstellung. Am ehesten als variabel zu charakterisierende Kosten fallen für den Betrieb der Netzinfrastruktur und den Kundenservice an.

Eine spezielle Stellung nehmen die sogenannten Terminierungsentgelte bei Gesprächen in andere Netze ein. Diese Interconnection-Gebühren wirken sich sowohl auf den Umsatz als auch auf die Kosten der Anbieter aus, da für eingehende Gespräche diese Gebühren kassiert werden können, während sie für abgehende Gespräche zu zahlen sind. Inzwischen haben sich die Interconnection-Gebühren zwischen den Mobilfunknetzen weitgehend angeglichen, entsprechend löschen sich diese Zahlungsströme zu einem guten Teil gegenseitig aus. Lediglich das zwischen dem Festnetz und den Mobilfunknetzen herrschende signifikante Preisgefälle führt in einer Saldobetrachtung zu positiven Umsätzen für die Mobilfunkanbieter zulasten der Festnetzanbieter.

Die Annahme quasi-fixer Kosten steht auf den ersten Blick im Widerspruch zu der Erkenntnis aus [Samanta et al. 2009], dass sich die Kosten für die Bereitstellung eines Zugangs für einen Netzbetreiber je Kunden auf monatlich ca. 0,10 US\$ belaufen und damit lediglich 7 %

der gesamten Kosten ausmachen (berechnet am Beispiel eines städtischen Mobilfunknetzes in Indien mit einer Million Kunden). In dieser Betrachtung wird aber nicht berücksichtigt, dass es sich bei den der Mobilfunknutzung zuordenbaren Kosten nur zu einem geringen Teil um originär variable Kosten handelt, weshalb die Fixkosten insgesamt deutlich höher ausfallen als lediglich die reinen Bereitstellungskosten.

Verlässt man den Bereich der „Produktion“ von Mobilfunkdiensten durch Netzbetreiber, so wird das Bild des Marktes unübersichtlich. Speziell in der vertrieblichen Schnittstelle zum Kunden ist der Mobilfunkmarkt weit aufgefüchert, wie Abbildung 6 zeigt.

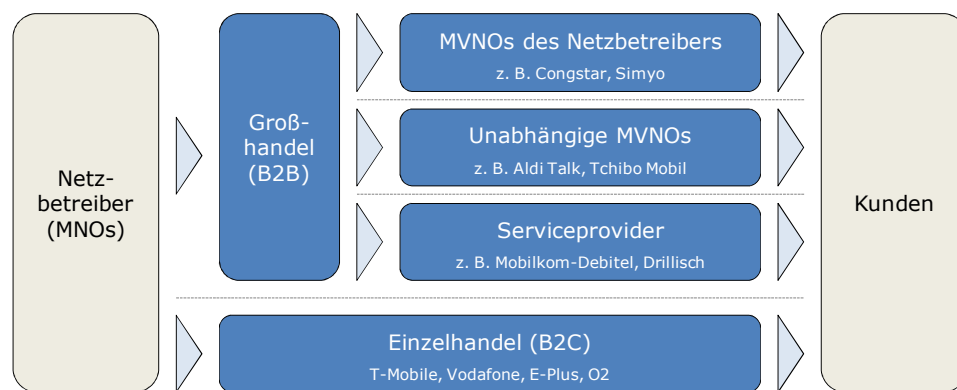


Abbildung 6: Etablierte Vertriebsmodelle im deutschen Mobilfunkmarkt

Quelle: eigene Darstellung

Neben den vier MNOs in der direkten Endkundenbetreuung finden sich hier auch sogenannte Serviceprovider, die kein eigenes Netz betreiben und unter eigenem Namen die Standardprodukte der MNOs an Endkunden verkaufen. Sie stellen einerseits einen alternativen Vertriebskanal dar, decken aber üblicherweise auch darüber hinaus große Teile der Wertschöpfungskette ab, wie den Kundenservice, das SIM-Karten-Management oder die Rechnungsstellung. Für den Kunden hat diese Vertriebsform den Vorteil, alle Netzbetreiber bei einem Anbieter vergleichen zu können und eine von den MNOs unabhängige Beratung zu erhalten. Die folgende Abbildung 7 zeigt die Bedeutung der Serviceprovider, die ca. ein Viertel des Gesamtmarktes bedienen. Der größte Vertreter am deutschen Mobilfunkmarkt ist hierbei Mobilcom-Debitel⁷ mit 17 Millionen Kunden (in 2009, vgl. [TeleGeography 2010]), mit weitem Abstand gefolgt von Drillisch⁸ (2 Mio. Kunden) und The Phone House⁹.

⁷ <http://www.mobilcom-debitel.de/>, abgerufen am 9. Februar 2010.

⁸ <http://www.drillisch-telecom.de/>, abgerufen am 9. Februar 2010.

⁹ <http://www.phonehouse.de/>, abgerufen am 9. Februar 2010.




Abbildung 7: Mobilfunk-Kundenzugang durch unabhängige Serviceprovider (Umsatzanteil am Gesamtmarkt)
 Quelle: eigene Darstellung; [Bundesnetzagentur 2009b] (S. 51 f.)

Neben den Service Providern gibt es noch eine Fülle sogenannter virtueller Netzbetreiber („mobile virtual network operator“, MVNO, vgl. [Gruber 2005], Kap. 5.7.3 und [Arthur D. Little/Exane BNP Paribas 2007], Kap. 2.3), die gegenüber den Kunden wie ein eigenständiger Netzbetreiber mit eigenem Produktspektrum auftreten, ihre Dienste aber bei einem MNO einkaufen. [TeleGeography 2010] zählt ca. 50 verschiedene MVNOs im deutschen Mobilfunkmarkt. Unter diesen finden sich sowohl Tochtergesellschaften der MNOs (z. B. Congstar¹⁰ von T-Mobile oder Simyo¹¹ von E-Plus), die als Zweitmarken mit abgegrenztem Fokus am Markt platziert werden, als auch eigenständige Unternehmen (z. B. Aldi Talk¹² oder Tchibo Mobil¹³).

Die Wertschöpfungskette zwischen dem Kundenkontakt und dem Netzbetrieb kann bei dem MVNO-Modell unterschiedlich aufgeteilt sein. Als Extreme gibt es auf der einen Seite MVNOs, die als zusätzliche Marke das Portfolio der MNOs ergänzen, ohne dass sie außerhalb des Marketings einen signifikanten Teil der Wertschöpfungskette autark verantworten. Auf der anderen Seite gibt es MVNOs, die eher dem Modell der klassischen Serviceprovider entsprechend lediglich Übertragungskapazität bei den Netzbetreibern einkaufen und die komplette übrige Wertschöpfung wie Marketing, Kundenservice, SIM-Karten-Management und Rechnungsstellung eigenständig betreiben.

Ungefähr 20 Millionen der deutschen Mobilfunkanschlüsse sind laut [Bundesnetzagentur 2009b] (S. 51) dem (schwer abgrenzbaren) Discountsegment zuzuordnen, dessen Anbieter mit günstigen und übersichtlichen Tarifstrukturen einen preisbewussten Kundenkreis ansprechen. Hier dominieren vor allem die Zweitmarken der Netzbetreiber, wie z. B. BASE¹⁴

¹⁰ <http://www.congstar.de/>, abgerufen am 9. Februar 2010.

¹¹ <http://www.simyo.de/>, abgerufen am 9. Februar 2010.

¹² <http://www.aldi-sued.de/>, abgerufen am 9. Februar 2010.

¹³ <http://www.tchibo.de/>, abgerufen am 9. Februar 2010.

¹⁴ <http://www.base.de/>, abgerufen am 9. Februar 2010.

von E-Plus oder Fonic¹⁵ von O₂, während Discountangebote von Service Providern nur eine untergeordnete Rolle spielen.

Bei einem Vergleich der Netzanbieter aus technischer Sicht schneiden die Marktführer T-Mobile und Vodafone etwas besser ab als die Konkurrenz von E-Plus und O₂. Zwar haben alle Betreiber beim Netzausbau inzwischen eine nahezu vollständige Versorgung der gesamten Bevölkerung erreicht, speziell die Abdeckung ländlicher unbesiedelter Gebiete ist aber traditionell durch die D-Netze weiter fortgeschritten. Hinsichtlich der erzielten Verfügbarkeit und Sprachqualität haben die E-Netze jedoch aufgrund des charakteristischen Frequenzspektrums und der technisch bedingten kleineren Zellstruktur leichte Vorteile speziell in Ballungsräumen.

Untersuchungen zur Servicequalität der Mobilfunkanbieter liefern das konsistente Bild, dass die vier originären Netzbetreiber durch ihre etablierten Prozesse und eine fortwährende Markenpflege einen Vorsprung gegenüber der Konkurrenz aus Service Providern und MVNOs haben (vgl. z. B. Abbildung 8).




Abbildung 8: Servicequalität der Mobilfunkanbieter (Anteil Bewertungen „besonders guter Service“)

Quelle: eigene Darstellung; [Chip Xonio Online 2007]

Zukünftige Innovationen im Hinblick auf den Vertrieb von Mobilfunkprodukten zeichnen sich bereits im Markt ab (vgl. [Solon 2005]). Mit Tchibo Mobil und Aldi Talk haben sich die ersten sogenannten „Branded Reseller“ am Markt etabliert. Diese Angebote stellen eine Zusammenarbeit zwischen einem MNO und einem Partner dar, dessen starke Marke dabei hilft, eine bestimmte Zielgruppe an Kunden kostengünstig zu akquirieren. Im Fall von Tchibo ist diese Zielgruppe „Frauen über 40“, während Aldi sich entsprechend dem Markenimage an preisbewusste Kunden richtet, ohne dabei jedoch die Hauptmarke des Partners E-Plus zu unterminieren.

Ebenfalls erfolgversprechend ist die Vermarktung von Mobilfunkangeboten im Kontext anderer Produkte. So treten Kabelnetzbetreiber als MVNO auf, um zusammen mit ihren hauseigenen Leistungen ein sogenanntes „Quadruple Play“-Angebot (zusammen mit Fernsehen, Festnetztelefonie und Internet) zu schnüren. Im Zuge der fortschreitenden Integration von Mobilfunkanwendungen ins Auto wird erwartet, dass die Autobauer selbst als MVNO

¹⁵ <http://www.fonic.de/>, abgerufen am 9. Februar 2010.

auftreten und einen Mobilfunkvertrag als Ausstattungsmerkmal des Fahrzeugs etablieren. Ähnlich verhält es sich mit Notebookherstellern, die als Zusatz zur ohnehin eingebauten UMTS-Karte auch gleich noch den passenden Mobilfunk-Datentarif anbieten können.

2.1.2. Tarife

Der Mobilfunkmarkt in Deutschland unterliegt im Gegensatz zum Festnetzmarkt weniger Regulationen, da keiner der Anbieter ein natürliches Monopol innehat. Entsprechend steht es den Anbietern weitgehend frei, sich mit einer innovativen und zielgruppengerechten Tarifgestaltung Wettbewerbsvorteile aufzubauen.

Drei grundlegende Tariftypen haben sich am Mobilfunkmarkt für Sprachtelefonie etabliert (vgl. z. B. [Skiera 1999], Kap. 4.1):

- (1) Klassische *Vertragstarife* mit einer monatlichen Grundgebühr, variablen Nutzungsgebühren und ggf. einem Kontingent an nicht abgerechneten Inklusivminuten
- (2) Rein nutzungsabhängige *Zeittarife*
- (3) Nutzungsunabhängige *Pauschaltarife* (sog. Flatrates)

Abbildung 9 charakterisiert diese Tariftypen anhand des funktionalen Zusammenhangs zwischen der Nutzung (in Mobilfunkminuten) und dem hierdurch generierten Umsatz. In der verwendeten Darstellung entspricht die Steigung der Nutzung-Umsatz-Kurve dem Grenzümsatz einer zusätzlichen Mobilfunkminute. Tarife mit Mindestumsatz (analog mit optionalen Minutenpaketen) lassen sich in dieser Klassifikation den Vertragstarifen zuordnen, da diese strukturell identisch sind mit der Kombination aus einer (zusätzlichen) Grundgebühr in Höhe des Werts des Mindestumsatzes und einer Inklusivnutzung in Höhe der Mindestnutzung (bzw. des Minutenpaketumfangs).

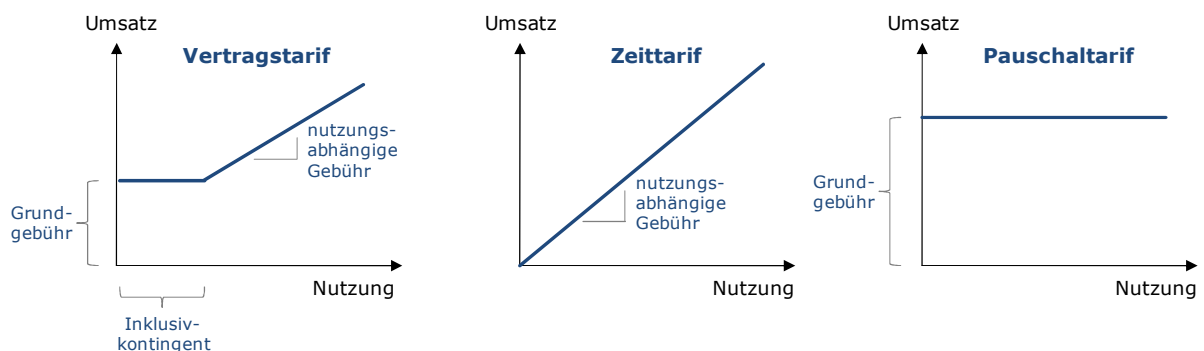


Abbildung 9: Grundlegende Tariftypen für Mobilfunk-Sprachtelefonie

Quelle: eigene Darstellung

Historisch betrachtet stellen Vertragstarife seit Beginn des Mobilfunkmarktes das überwiegend eingesetzte Tarifkonstrukt dar, während sich Zeit- und Pauschaltarife erst ab dem Jahr 2005 im Zuge des Markteintrittes von Discountanbietern auf dem deutschen Markt etablieren konnten. Reine Zeittarife haben sich als sogenannte „no frills“-Angebote seitdem weit verbreitet. Selten findet man hingegen wirkliche Pauschaltarife, sondern eher Mischformen, die lediglich netzinterne (sog. „on-net“) Gespräche und Telefonate ins Festnetz mit

einer Pauschalgebühr abdecken, während Gespräche in andere Mobilfunknetze weiterhin nutzungsbasiert abgerechnet werden.

Durch die gezeigte Auffächerung des Tarifportfolios können die Anbieter unterschiedliche Nutzergruppen mit entsprechend unterschiedlichem Nachfrageverhalten gezielt mit einem abgestimmten Angebot adressieren. Man bezeichnet dieses Konzept als eine mengenbezogene Preisdifferenzierung (vgl. [Skiera 1999]), da je nach nachgefragter Menge unterschiedliche Preise zu zahlen sind. Eine solche Preisdifferenzierung ist augenscheinlich zwischen den Tarifen der Fall, doch auch innerhalb des Vertrags- und Pauschaltarifs ändert sich der Preis mit der Nutzungsmenge. Der durchschnittliche Preis einer Nutzungseinheit nimmt bei einem Pauschaltarif kontinuierlich mit steigender Nutzung ab, während er beim Zeittarif konstant bleibt. Beim Vertragstarif stellt die Preisdifferenzierung eine Vermischung der beiden übrigen Tariftypen dar (vgl. [Tacke 1989]).

Begünstigt wird die mengenbezogene Preisdifferenzierung im Mobilfunk durch die bereits in Kapitel 2.1.1 diskutierte Tatsache, dass für Netzbetreiber die variablen Kosten kaum ins Gewicht fallen (vgl. auch [Skiera 1999], S. 15). Somit erzielt aus Sicht einer Kostenrechnung jede zusätzliche Nutzung im Allgemeinen einen positiven Deckungsbeitrag. Dadurch ist jede Form der Preisdifferenzierung zielführend, die sich umsatzsteigernd auswirkt.

Die Differenzierung des Produktangebots in verschiedenen Tariftypen ist sinnvoll für die Anbieter, da so über den originären Nutzen des Mobilfunkprodukts hinaus weitere Zahlungsbereitschaften abgeschöpft werden können. Beispielsweise zeigen [Lambrecht und Skiera 2006a] und [Lambrecht und Skiera 2006b], wie sogenannte Tarifwahl-Biases aufseiten der Kunden die Umsätze der Anbieter durch zusätzliche Zahlungsbereitschaften signifikant steigern können. Empirisch belegen die Autoren dies bei Pauschaltarifen für deren inhärenten Versicherungseffekt gegen schwankende laufende Kosten, für den sogenannten Taxametereffekt, der den größeren Genuss beim Konsum eines nicht variabel abgerechneten Produkts beschreibt, sowie für die Option zusätzlicher kostenfreier Nutzung. Kunden bewerten solche Tarifeigenschaften wie einen eingebauten Mehrwert, für den viele von ihnen bereit sind, ein Premium zu bezahlen. Auch aus der Tatsache, dass Kunden ihr Nutzungsverhalten nur bedingt korrekt einschätzen können (vgl. [Rams 2001], speziell eine Überschätzung tritt häufig auf, vgl. [Lambrecht und Skiera 2006b] und [Gerpott 2009]), entstehen ebenfalls zusätzliche Zahlungsbereitschaften, die von den Anbietern insbesondere durch Pauschaltarife geschickt abgeschöpft werden. Diese Überlegung hat jedoch auch eine Kehrseite für die Anbieter, da mangels Grenzkosten für den Kunden durch Pauschaltarife zusätzliche Nachfrage entstehen kann, indem die Kunden ihre Nutzung erweitern. Selbst wenn man von vernachlässigbaren variablen Kosten der Anbieter ausgeht, kann diese induzierte exzessive Nutzung zu Engpässen und Überlastungen bei der Zugangs- und Übertragungskapazität der MNOs und damit zu Qualitätsproblemen führen.

Neben den grundlegenden Tariftypen haben sich verschiedene Rabattkonzepte bei den meisten Anbietern etabliert. Die größte Bedeutung haben hier sicherlich die „on-net“-Rabatte für netzinterne Gespräche (eine sog. terminierungsbasierte Preisdiskriminierung). Da bei diesem Typus von Telefonat keine Interconnection-Gebühren an andere Netzbetreiber abzu-

führen sind, können die Anbieter hier diese reale Kosteneinsparung an die Kunden weitergeben (vgl. [Gruber 2005], S. 196). Vereinzelt werden auch ähnliche Rabatte für Telefonate zu vorab definierten Gegenstellen wie z. B. Freunden oder Familienmitgliedern gewährt.

Ursprünglich nur vom Anbieter O₂ im Tarif „Genion“ offeriert, haben sich sogenannte „Homezone“-Rabatte inzwischen auf breiterer Front durchgesetzt. Hierbei werden abgehende Gespräche innerhalb eines engen räumlichen Radius um die Wohnung des Kunden für einen stark reduzierten Preis verkauft, um so ein konkurrenzfähiges Angebot gegenüber einem Festnetzanschluss zu ermöglichen. Auf diesem Wege entsteht eine Art von konvergentem Produkt zwischen dem Festnetz und dem Mobilfunk, ohne jedoch eine technische Integration vollziehen zu müssen. Über das Homezone-Konzept hinaus haben sich keine Rabatte oder generell Tarife etabliert, die eine Preisdifferenzierung aufgrund geografischer Aspekte – vergleichbar zu Ferngesprächen im Festnetz – implementieren.

Noch komplexer wird die Preisgestaltung durch verschiedene Bonus- und Malus-Regelungen der Anbieter. Als Bonus sei z. B. die teilweise angebotene Abrechnung im Sekundentakt erwähnt. Diese führt zu einer signifikanten Verbilligung kurzer Gespräche, und auch im Mittel fällt je Telefonat eine halbe Minute weniger Nutzung an. Als Malus berechnen verschiedene Anbieter Einmalkosten für den Abschluss eines Tarifs, speziell während der oligopolistischen Marktentwicklung waren diese Gebühren mangels wirklicher Konkurrenz weit verbreitet.

Hinsichtlich weiterer nicht preisspezifischer Tarifcharakteristika ist vor allem die Mindestvertragslaufzeit zu nennen. Durch diese können Anbieter ihre Kunden vor allem bei Vertrags- und Pauschaltarifen mittelfristig an sich binden. Üblicherweise ist innerhalb der Mindestvertragslaufzeit lediglich ein Wechsel in einen Tarif mit höherer Grundgebühr möglich, nicht jedoch zu einem Tarif mit niedrigerer Grundgebühr.

Wenngleich die Einführung von Prepaidtarifen am Mobilfunkmarkt als echte Produktinnovation aufgenommen wurde (vgl. [Gruber 2005], Kap. 5.3.2) und zu einem signifikanten Wachstum der Kundenzahlen geführt hat, so entspricht diese Maßnahme in ihrem Kern lediglich einer Umstellung des Zahlungsprozesses. Die vorgelagerte Einzahlung eines Guthabens an sich hat keinen Einfluss auf den Preis des Tarifs, sondern allenfalls auf dessen Attraktivität. Es handelt sich hierbei also nicht um ein im Rahmen dieser Arbeit zentral zu betrachtendes Charakteristikum des Tarifs.

Aktuelle Tarifentwicklungen zielen in zwei Stoßrichtungen (vgl. auch [Solon 2005]): Zum einen wird die Flexibilität der Kunden bei der Auswahl der Tariftypen erhöht, zum anderen werden Kostenobergrenzen auch bei Vertragstarifen angeboten. E-Plus offeriert mit „Mein Base“¹⁶ beispielsweise einen hochgradig flexibel konfigurierbaren Tarif, bei dem der Kunde selbst entscheiden kann, welche Telefonate (ins Festnetz, on-net oder in andere Mobilfunknetze) er pauschal abgerechnet haben möchte, und für welche Telefonate er dagegen einen Zeittarif bevorzugt. O₂ hat mit dem Tarif „O“¹⁷ das Konzept des Kosten-Airbags im Markt

¹⁶ <http://www.base.de/tarife/mein-base.jsf>, abgerufen am 29. März 2010.

¹⁷ <http://www.o2online.de/nw/tarife/o/o2o.html>, abgerufen am 29. März 2010.

eingeführt, das eine Vermischung zwischen Vertrags- und Pauschaltarif darstellt. Hierbei wird ein klassischer Vertragstarif um die Sicherheit erweitert, nie mehr als einen bestimmten Maximalbetrag bezahlen zu müssen.

2.1.3. Nutzungs- und Tarifwahlverhalten der Kunden

Die Kunden im Mobilfunkmarkt schließen Tarife bei den Anbietern ab und ermöglichen sich so die Befriedigung ihrer Nachfrage nach Mobiltelefonie. Häufig beinhaltet der Abschluss eines Tarifs auch den Kauf eines subventionierten Mobiltelefons. Als Maß für den Markterfolg der Mobiltelefonie und damit für die Akzeptanz beim Kunden wird allgemein die Penetrationsrate herangezogen, die den Anteil der abgeschlossenen Mobilfunktarife mit der Größe der Gesamtbevölkerung ins Verhältnis setzt. Wie Abbildung 10 zeigt, hat sich die Mobiltelefonie um das Jahr 2000 herum zu einem Massenmarkt entwickelt, und seit 2006 übersteigt die Anzahl der abgeschlossenen Mobilfunktarife sogar die Größe der Gesamtbevölkerung, was in einer statistischen Penetration von über 100 % resultiert. Daraus kann man einen ungebrochenen Trend hin zum Zweit- oder sogar Dritthandy ableiten, viele Mobilfunkkunden besitzen also mehrere Mobiltelefone mit unterschiedlichen Tarifen. Bei einer nicht repräsentativen Umfrage von [Chip Xonio Online 2007] haben z. B. 61 % der Umfrageteilnehmer angegeben, mehr als ein Mobiltelefon zu besitzen. Dieser ökonomisch nicht augenscheinlich einleuchtende Zustand ist vielfältig begründet, beispielsweise um eine Trennung von privaten und geschäftlichen Telefonaten sicherzustellen, um verschiedene Grade der Veröffentlichung von Telefonnummern zu ermöglichen oder um die entstehenden Kosten auf unterschiedliche Träger aufzuteilen. Lange Mindestvertragslaufzeiten und ein träges Kündigungsverhalten erschweren außerdem den vollständigen Wechsel zu einem neuen Anbieter und führen so zu Altlasten, d. h. zu faktisch nicht (mehr) genutzten Tarifabschlüssen.




Abbildung 10: Mobilfunk-Penetration (durchschnittlich, unter Einbeziehung mehrerer Anschlüsse pro Person)
 Quelle: eigene Darstellung; Bundesnetzagentur, <http://www.bundesnetzagentur.de>, abgerufen am 19. März 2010; Statistisches Bundesamt, <http://www.destatis.de>, abgerufen am 19. März 2010

Im Vergleich zu seinen europäischen Nachbarländern hat Deutschland damit eine recht hohe Mobilfunk-Penetration (vgl. Abbildung 11), lediglich in Österreich und Italien gibt es durchschnittlich mehr Tarifabschlüsse für Mobiltelefonie.




Abbildung 11: Mobilfunk-Penetration im europäischen Vergleich (2008, ausgewählte Länder nach höchstem BIP)

Quelle: eigene Darstellung; [International Telecommunication Union (ITU) 2009] (S. 68)

Betrachtet man wie in Abbildung 12 gezeigt die Verteilung der Mobilfunk-Penetration nach Altersgruppen (hier ohne die Zählung mehrfacher Tarife pro Person), sieht man, dass sich in der jüngeren Generation das Mobiltelefon als ein absoluter Alltagsgegenstand etabliert hat, und selbst in der eher wenig technophilen Generation der Rentner hat die Mobiltelefonie eine weite Verbreitung erreicht.




Abbildung 12: Mobilfunk-Penetration nach Altersgruppen (2008, ohne Zählung mehrerer Anschlüsse pro Person)

Quelle: eigene Darstellung; [Bundesministerium für Wirtschaft und Technologie (BMWi) 2009] (S. 138)

Neben der in der vorliegenden Arbeit zentral betrachteten Sprachtelefonie hat der Mobilfunk noch weitere Nutzungsfelder, wie in Abbildung 13 ersichtlich wird. Vor allem das Schreiben von Textnachrichten (SMS) als einfache Form der Datenübertragung hat eine weite Verbreitung gefunden, wird aber zunehmend durch fortgeschrittenere Datendienste wie z. B. Email ergänzt bzw. ersetzt.




Abbildung 13: Nutzung des Mobiltelefons (Anteil Umfrageteilnehmer)

Quelle: eigene Darstellung, [Focus Verlag/TNS Infratest 2009] (S. 65)

Gesamthaft betrachtet zeigt der Mobilfunkmarkt auf der Nachfrageseite ein starkes Wachstum, getrieben durch die zunehmende Alltäglichkeit der Mobiltelefonie, sinkende Preise und die fortschreitende Verbreitung von Pauschalangeboten. Abbildung 14 stellt diese Entwicklung im Verlauf der Jahre dar.




Abbildung 14: Entwicklung des Mobilfunk-Sprachverkehrs

Quelle: eigene Darstellung; [Bundesnetzagentur 2008] (S. 79); [Bundesnetzagentur 2009a] (S. 91)

Bei einer Analyse der Mobilfunkkunden wird häufig zuerst zwischen Privat- und Geschäftskunden unterschieden. Dies spiegelt sich auch in der marktseitigen Aufstellung der Mobilfunkanbieter wider, die mit getrennten Angeboten um diese beiden Zielgruppen werben. Grundgedanke hinter dieser Segmentierung ist die Unterstellung eines grundlegend unterschiedlichen Nutzungsverhaltens. Während bei Geschäftskunden eine intensive Nutzung, hohe Qualitätsansprüche und eine eher geringe Preissensitivität angenommen werden, haben Privatkunden ein in diesen Aspekten genau entgegengesetztes Profil. Diese Klassi-

fikation hat sich bereits zu Beginn des Mobilfunkmarktes etabliert und war lange Zeit auch inhaltlich treffend, inzwischen verschwimmen die Unterschiede zwischen beiden Nutzergruppen allerdings zusehends. Während bei Geschäftskunden einerseits die standardisierten Einkaufsprozesse der Unternehmen Druck auf die Preisstruktur ausüben und andererseits auch Mitarbeiter mit geringerer Mobilfunknutzung ein Mobiltelefon von ihrem Arbeitgeber gestellt bekommen, entwickelt sich die Nachfrage vieler Privatkunden, stimuliert durch Pauschaltarife und die Substitution von Festnetzanschlüssen, deutlich nach oben.

Betrachtet man die Quellen und Ziele von Mobilfunkgesprächen (vgl. Abbildung 15), so fällt der hohe Anteil der „on-net“-Gespräche mit Quelle und Ziel im selben Netz auf. Zum einen bestätigt das die Hypothese, dass bei miteinander in Kontakt stehenden Personen auch die Auswahl eines Anbieters positiv korreliert ist, zum anderen illustriert es aber auch die Wirksamkeit der im Folgenden eingehender diskutierten „on-net“-Rabatte. Obwohl die möglichen „on-net“-Gesprächspartner je nach Marktanteil des Netzbetreibers maximal ein Drittel des Gesamtmarktes repräsentieren, werden statistisch gesehen über dreimal so viele Minuten mit diesen Gesprächspartnern telefoniert im Vergleich zu Gesprächspartnern in anderen Netzen.




Abbildung 15: Quell- und Zielnetze der Mobilfunkgespräche (Anteil an der gesamten Gesprächsdauer, 2008)
Quelle: eigene Darstellung; [Bundesnetzagentur 2009b] (S. 53)

Analysiert man die Grundlagen des Nutzungsverhaltens im Telekommunikationsmarkt näher, so stößt man in der Literatur primär auf eine starke Preisabhängigkeit (vgl. z. B. [Skiera 1999], Kap. 3). Im heutigen Mobilfunkmarkt mit seinem niedrigen Preisniveau ist dieser Zusammenhang jedoch nicht mehr so stark ausgeprägt wie früher. Aktuelle Befragungen unter Mobilfunkkunden deuten aber weiterhin auf eine vorhandene Preiselastizität der Nachfrage bei manchen Kunden hin. So geben 35 % der Kunden in [TNS Infratest/E-Plus Gruppe 2010] (S.13) etwa an, bei sinkenden Preisen häufiger zu telefonieren, und 27 % gehen von einer längeren Gesprächsdauer aus. Größtenteils wird das Mobiltelefonieren aber nicht mehr als (eher preiselastischer) Konsum empfunden, sondern stellt eine in den Lebensablauf integrierte alltägliche Handlung dar, die nicht ständig aufgrund des zu zahlenden Preises reflektiert wird.

Für die weitere Entwicklung der Nachfrage im Mobilfunkmarkt kann man daraus ableiten, dass bei Preissenkungen zumindest von einer gewissen zusätzlichen preisinduzierten Nachfrage sowohl bei der Anzahl als auch bei der Länge der Gespräche ausgegangen werden kann. In [Solon 2005] wird ebenfalls eine derartige preiselastische Nachfrage für den deutschen Mobilfunkmarkt diagnostiziert, die mittelfristig zu einem stabilen Umsatz pro Kunde führen soll.

Die Entscheidung, welchen Tarif ein Kunde bei welchem Anbieter wählt, ist komplex und von verschiedenen Faktoren beeinflusst. Viele empirische Studien haben sich mit diesem Thema in unterschiedlichen Telekommunikationsmärkten (Festnetz wie auch Mobilfunk) beschäftigt, leider ohne ein vollständig kohärentes Bild der dominierenden Einflussfaktoren zu liefern. Im Folgenden sind die Ergebnisse einiger dieser Studien in chronologischer Reihenfolge aufgelistet.

- Laut [Gerpott 1998] hat der Preis einen 1,5-3fach so hohen Einfluss auf die Kaufentscheidung wie alle anderen Kriterien.
- [Ringle 2000] befragt im Festnetz operierende Telekommunikationsunternehmen nach deren Sicht über die für ihre Kunden wichtigen Entscheidungsfaktoren. Im Privatkundenbereich dominieren demnach die preisbezogenen Einflüsse (wie die Höhe der Preise sowie die Einfachheit der Tarifstruktur) im Gegensatz zu den qualitätsbezogenen Aspekten (wie Verbindungsqualität, Service oder das Image), bei Geschäftskunden hingegen sind die Präferenzen entgegengesetzt verteilt.
- [Birke und Swann 2005] finden bei einer Befragung unter Studenten heraus, dass deren wichtigste Entscheidungskriterien bei der Auswahl eines Mobilfunkanbieters der Preis, Sonderaktionen sowie die Möglichkeit, im Rahmen von „on-net“-Rabatten kostengünstig mit Freunden und Familienmitgliedern zu telefonieren, sind. Die Qualität des Mobilfunknetzwerks sowie die Subventionierung von Endgeräten sind demgegenüber klar untergeordnet, der Kundenservice spielt eine noch geringe Rolle.
- [Kreye 2005] (Kap. 4.2.1) ordnet die entscheidungsrelevanten Faktoren für die Kaufentscheidung eines Kunden im Mobilfunkmarkt anhand deren Bedeutung. Dominierend sind niedrige Preise, eine gute Netzabdeckung und eine gute Sprachqualität, gefolgt von einem verlässlichen Kundenservice, freundlichem Verkaufspersonal, modernen und zentral gelegenen Handy-Shops sowie zuletzt vom Prestige des Anbieters.
- [Munnukka 2005] zeigt in seiner Studie unter finnischen Mobilfunknutzern, dass bei intensiven Nutzern vor allem die Preiswahrnehmung und der Innovationsgehalt bei der Beurteilung von Mobilfunkdienstleistungen eine Rolle spielen, während Durchschnittsnutzer neben dem Preis auch auf die Servicequalität achten.
- [Hansen 2006] zeigt das Ergebnis einer Kundenbefragung hinsichtlich der fünf wichtigsten Aspekte bei der Kaufentscheidung im Mobilfunk bzw. beim Wechsel eines Mobilfunkanbieters. Es dominiert der Wunsch nach sehr günstigen Gesprächskosten und nach einem Wegfall der Grundgebühren. Eine gute Netzqualität wird ebenfalls als wichtig erachtet, gefolgt von einem subventionierten Endgerät und einem generell einfachen Gebührenmodell.

- [Harter et al. 2007] stellen bei einer Studie mit 1.800 amerikanischen Mobilfunkkunden fest, dass der Preis der mit Abstand wichtigste Entscheidungsfaktor für einen Mobilfunkvertrag ist. Lediglich für Nutzer mit hohem Gesprächsaufkommen spielt zusätzlich auch der Netzbetreiber eine signifikante Rolle.
- [Lim und Kumar 2008] bestätigen in ihrer empirischen Studie unter amerikanischen Mobilfunknutzern die Hypothese, dass bei der Auswahl eines Mobilfunkanbieters für Frauen Qualitätsaspekte eine zentrale Rolle spielen, während Männer sich eher am Preis-Leistungs-Verhältnis orientieren.
- [Stingel 2008] (S. 8) leitet aus einer Befragung unter Geschäftskunden ab, dass Preisfaktoren (vgl. [Stingel 2008], S. 172) sowie sonstige Attraktivitätsfaktoren (wie Service- und Netzqualität) bei der Entscheidung für einen Mobilfunktarif die weitaus größte Bedeutung haben und sich untereinander ungefähr die Waage halten. Auch die Treue zu einem bereits in der Vergangenheit gewählten Anbieter (in der Literatur häufig als „stickiness“ bezeichnet) und die resultierende Trägheit hinsichtlich davon abweichender Entscheidungen haben einen Einfluss (vgl. [Stingel 2008], S. 69).
- [Corrocher und Zirulia 2009] finden bei einer Befragung von 193 italienischen Schülern bzw. Studenten heraus, dass die Netzabdeckung und die Attraktivität der angebotenen Tarife von primärer Bedeutung für die Entscheidung dieser Mobilfunkkunden sind. Speziell bei Kunden mit einer intensiven Nutzung spielen aber auch lokale Netzwerkeffekte, d. h. die Verbreitung des Anbieters in ihrem sozialen Netzwerk (Freunde, Familie und Partner) eine entscheidende Rolle.
- [Focus Verlag/TNS Infratest 2009] (S. 62) liefert umfassende Einblicke, welche Kriterien durch Mobilfunkkunden bei der Tarifwahl berücksichtigt werden. Unter den von den Umfrageteilnehmern zu nennenden fünf wichtigsten Kriterien dominieren eindeutig die kostenbezogenen Kriterien, z. B. orientieren sich 75 % am Verhältnis von Preis und Leistung. Hoch im Kurs stehen hierbei flexible Tarife ohne Mindestumsatz (60 %) bzw. generell ohne Grundgebühr (44 %). Neben dem zu zahlenden Preis spielen auch qualitätsbezogene Aspekte wie die Netzabdeckung und Erreichbarkeit für 56 % eine wichtige Rolle. Immerhin 20 % der befragten Mobilfunknutzer geben an, dass bei der Auswahl die Empfehlungen von Freunden und Bekannten einen signifikanten Einfluss haben.

Betrachtet man die keineswegs einheitlichen Erkenntnisse dieser Studien, so kann man doch ein übergreifend identifiziertes Motiv bei der Tarifwahl feststellen, nämlich die Berücksichtigung der erwarteten Kosten bei Abschluss eines Tarifs. Hat ein Kunde Klarheit über sein zukünftiges Nutzungsverhalten, so kann er durch einen Vergleich der drei Funktionen aus Abbildung 9 für eine definierte Nutzung (x-Achse) leicht die Kosten der verschiedenen Tarife (y-Achse) ermitteln und den günstigsten Tarif identifizieren. In der Realität ist die Einschätzung des zukünftigen Nutzungsverhaltens aber nur stark unsicherheitsbehaftet möglich, wie auch [Stingel 2008] (S. 172) bemerkt. Eine Überschätzung der Nutzung führt dann potenziell zu einem Tarif mit einer überhöhten Grundgebühr und evtl. ungenutzten Inklusivminuten, eine Unterschätzung führt hingegen zu einer fälschlichen Ablehnung von Tarifen mit hohen Grundgebühren und günstigeren nutzungsabhängigen Gebühren.

Neben der initialen Entscheidung für einen Mobilfunkanbieter überprüfen die Kunden regelmäßig ihre getroffene Entscheidung und sind gegebenenfalls auch bereit, die Entscheidung zu revidieren und zu einem anderen Anbieter zu wechseln. Empirische Studien belegen das Vorhandensein dieser latenten Wechselbereitschaft. Bei [TNS Infratest/E-Plus Gruppe 2010] (S.4) geben z. B. 20 % der Mobilfunkkunden an, in den vergangenen zwei Jahren ihren Tarif oder ihren Anbieter aus Kostengründen gewechselt zu haben. Bei der Studie von [Chip Xonio Online 2007] geben 21% der Umfrageteilnehmer an, innerhalb des nächsten Jahres ihren Anbieter wechseln zu wollen, überwiegend aus Kostengründen. Diese Anteile waren in vorangegangenen Jahrgängen beider Studien sogar noch höher. Der Trend kann aber leicht dadurch erklärt werden, dass das allgemeine Preisniveau in diesem Zeitraum gefallen ist, und sich somit auch die durch einen Wechsel realisierbaren Kosteneinsparungen verringert haben. Die Studie von [Stern 2006] kommt ebenfalls zu dem vergleichbaren Ergebnis, dass 21% der Personen, die ein Mobiltelefon zur persönlichen Verfügung haben, innerhalb des nächsten halben Jahres „vielleicht“ oder „sicher“ ihren Netzanbieter wechseln wollen.

Die im Markt gemessene Abwanderungsquote (fachsprachlich als „churn rate“ bezeichnet) dokumentiert diese Wechselbereitschaft: Wie Abbildung 16 zeigt, verlieren die Anbieter jeden Monat durchschnittlich 1,57 % ihrer Kunden. Aufgrund der hohen Marktdurchdringung kann kaum davon ausgegangen werden, dass sich ein signifikanter Anteil dieser ehemaligen Kunden aus dem Markt zurückzieht, vielmehr werden diese wieder als Neukunden bei der Konkurrenz verbucht.




Abbildung 16: Monatliche Churn-Rate

Quelle: eigene Darstellung; [Merrill Lynch 2009]

Einen interessanten Seitenaspekt zum Wechselverhalten erläutert [Gerpott 2009]: Demnach haben Kunden mit einem Pauschaltarif eine geringere Churn-Wahrscheinlichkeit, selbst wenn sie mit ihrem Tarif nicht die kostenoptimale Wahl getroffen haben (sog. „Flatrate-Bias“). Da die Abwanderung von Kunden mit hohen Kosten für die Neukundenakquisition verbunden ist, lässt sich also leicht nachvollziehen, warum Pauschaltarife auch für die Anbieter ein attraktiver Tariftyp sind, selbst wenn durch dieses Angebot über den Pauschalbetrag hinausgehende Umsätze nicht realisiert werden können.

2.1.4. Besonderheit im Markt: Netzwerkeffekte

Neben den im vorigen Kapitel gezeigten Einflussfaktoren bei der Bewertung von Tarifen spielen im Mobilfunkmarkt *Netzwerkeffekte* (vgl. [Birke 2009]) eine tragende Rolle. Diese stehen auch im speziellen Fokus der vorliegenden Arbeit. Ausgangspunkt für die Identifikation von Netzwerkeffekten ist die häufige empirische Beobachtung, dass Anbieter, die im sozialen Umfeld des jeweiligen Kunden verbreitet sind, bevorzugt ausgewählt werden (vgl. z. B. [Birke und Swann 2005], oder [Birke 2009] für eine Übersicht empirischer Studien). Im Mobilfunkmarkt hat dies neben psychologischen Gründen und individuellen praktischen Erwägungen auch finanzielle Motivationen, was im Folgenden näher ausgeführt wird.

Von Netzwerkeffekten (in der deutschen Literatur häufig auch schlicht als Netzeffekte bezeichnet, wie z. B. bei [Wiedemer 2007]) spricht man allgemein, wenn der Nutzen eines Gutes steigt, je mehr Konsumenten dieses Gut gebrauchen (vgl. [Katz und Shapiro 1985] für eine weitergehende Definition solcher direkten Netzwerkeffekte). Es handelt sich hierbei um einen von der Nutzungsentscheidung anderer Kunden abgeleiteten (derivaten) Nutzen, der gegebenenfalls neben dem originären Nutzen des Produkts besteht (vgl. [Clement und Schollmeyer 2009] oder [Liehr 2005], Kap. B.1.1). Da dieser zusätzliche Nutzen kein inhärenter Teil des Produkts selbst ist (sondern von extern kommt), hat sich hierfür auch der Begriff der Externalität eingebürgert. Netzwerkeffekte wirken in der Regel selbstverstärkend, was bedeutet, dass ihre Auswirkung – der verstärkte Gebrauch eines Gutes – abermals den Nutzen des Gutes steigert.

Wenn Netzwerkeffekte im Kontext der Telekommunikation betrachtet werden, denkt man zumeist an den grundsätzlichen Zusammenhang, dass die Menge der erreichbaren Teilnehmer mit jedem zusätzlichen Telekommunikationsanschluss zunimmt, und damit der Nutzen der Telekommunikation an sich steigt. Der Effekt spiegelt sich dann auch analog beim Nutzungsverhalten wider, je mehr Teilnehmer erreichbar sind, desto mehr Kommunikation wird über das Telefon im Vergleich zu alternativen Kanälen abgewickelt. Diese Aspekte spielen zwar in einer makroskopischen Betrachtung der Entwicklung des Gesamtmarktes eine entscheidende Rolle, haben aber zumindest in den heutigen, weitgehend gesättigten Mobilfunkmärkten nur einen begrenzten Einfluss auf das Entscheidungsverhalten einzelner Kunden.

Relevant für das Entscheidungsverhalten der Kunden sind hingegen die im Mobilfunkmarkt stark ausgeprägten lokalen Netzwerkeffekte (vgl. [Birke 2009], Abs. 3.3). Hierbei ist die Grundgesamtheit der Kunden, die einen Netzwerkeffekt ausüben, nicht wie z. B. in [Grajek 2007] oder [Doganoglu und Grzybowski 2007] durch den Gesamtmarkt bestimmt, sondern durch die abgegrenzte soziale Umgebung (die *Nachbarschaft*) des jeweiligen Individuums, welche bei der Entscheidungsfindung direkt berücksichtigt wird (vgl. [Sundararajan 2007], oder [Wendt et al. 2000] für ein Beispiel). Der Nutzen eines Produkts steigt hierbei also nur aufgrund der lokalen Verbreitung in der persönlichen Nachbarschaft eines Kunden (vgl. z. B. [Cohendet 1998]). Von außen betrachtet wirken solche Netzwerkeffekte demnach wie eine Gravitationskraft für bereits lokal verbreitete Produkte. Im Gegensatz zu idealtypischen Netzwerksgütern, die ihren Nutzen hauptsächlich oder sogar ausschließlich aus Netzwerkeffekten beziehen, haben Mobilfunkprodukte aber durchaus auch einen netzwerk-

unabhängigen Grundnutzen. Dieser Grundnutzen wird durch Netzwerkeffekte lediglich ergänzt und erhöht so die Attraktivität und Konkurrenzfähigkeit des Produkts.

Prägend für die wissenschaftliche Forschung zu Netzwerkeffekten ist die Diffusionsforschung (vgl. [Valente 1995] oder [Rogers 2003]), bei der die Durchdringung eines Produkts auf dem Gesamtmarkt die determinierende Größe darstellt. Die Frage, warum ein Produkt überhaupt adoptiert wird (bzw. warum nicht), spielt hierbei kaum eine Rolle, vielmehr ist der Ablauf der Adoption im Markt der zentrale Gegenstand des Forschungsinteresses. Jedoch diskutieren bereits [Rogers und Kincaid 1981] (Kap. 5) den Einfluss, den die von den Autoren so benannte „individuelle Verbundenheit“ und die hierdurch übertragenen Informationen auf das Verhalten von Individuen haben.

Zunehmend setzt sich auch in der aktuelleren Betriebswirtschaftslehre die Erkenntnis durch, dass die Berücksichtigung des sozialen Umfelds eines Kunden für eine Analyse des individuellen Entscheidungsverhaltens notwendig ist (vgl. [Farrell 1998]). Beispielsweise gibt es bei der Bestimmung des Werts eines Kunden für einen Anbieter sowohl in der Wissenschaft (vgl. [Hogan et al. 2003]) als auch in der unternehmerischen Praxis (vgl. das Angebot der Firma Xtract¹⁸ zur Analyse individueller sozialer Netzwerke) erste derartige Ansätze.

Für die Tarifentscheidungen der Kunden auf dem Mobilfunkmarkt lassen sich vier Einflussfaktoren identifizieren, die ihren Ursprung im sozialen Netzwerk des Kunden haben und somit zu Netzwerkeffekten führen können:

- (1) Finanzielle Rabatte innerhalb des (sozialen) Netzwerks
- (2) Reduzierung der Bewertungsunsicherheit durch Empfehlungen
- (3) Imitation anderer Kunden aus Gründen der Hilfesuche
- (4) Imitation anderer Kunden aus Reputationsgründen (Mitläufereffekt)

Aufgrund der direkten Preiswirksamkeit sind insbesondere (1) finanzielle Rabatte wie z. B. für „on-net“-Telefonate auf dem Mobilfunkmarkt von Bedeutung. Dabei werden die Gesprächspartner nur nach deren Netzbetreiber beurteilt, der Terminologie von [Katz und Shapiro 1985] folgend sind unterschiedliche Tarife der Gesprächspartner beim selben Netzbetreiber also bezüglich der Netzwerkeffekte kompatibel zueinander. Zusätzlich erweitern einzelne Anbieter dieses Konzept als sogenannte Community-Rabatte auch auf Telefonate zu vorab als rabattiert vereinbarten Rufnummern. Laut [Farrell 1998] hat der „Friends&Family“-Tarif des auf dem amerikanischen Markt tätigen Anbieters MCI erstmals eine solche Idee im Jahr 1991 aufgegriffen, indem ein Rabatt von 20 % auf Telefonate zu 20 geworbenen Neukunden gewährt wurde. Zwar bedeuten solche Rabattarten zwangsläufig einen entgangenen Umsatz, diesen Opportunitätskosten stehen aber potenziell weitreichende Auswirkungen auf die relative Positionierung des Anbieters im preissensitiven Wettbewerb gegenüber, die bis hin zu einer Abschottung der Kunden gegenüber konkurrierenden Anbietern führen können.

¹⁸ <http://www.xtract.com/>, abgerufen am 15. Januar 2010.

Bei Mobilfunkprodukten handelt es sich wie bereits skizziert um komplexe Produkte mit schwer durchschaubaren Tarifstrukturen. Um die Unsicherheit bei der individuellen Bewertung eines Tarifs zu reduzieren, greifen Kunden im Mobilfunk häufig auf (2) die Empfehlungen von Freunden oder Familienmitgliedern zurück (vgl. [Janssen und Jäger 2003]). Sowohl positive als auch negative Empfehlungen können sich über das soziale Umfeld ausbreiten und in vielen empirischen Studien wird kontrovers diskutiert, welche dieser Einflüsse in der jeweiligen Industrie und Entscheidungssituation überwiegen. Eindeutig positiv ist jedoch der Effekt, dass sich ein Kunde durch die Übernahme einer Auswahlentscheidung aus dem sozialen Umfeld (3) einfachere Hilfe bei möglichen Problemen erhofft. Häufig trifft man z. B. auf ältere Personen, die sich aus genau diesen Gründen an der Anbieter- und Tarifwahl ihrer eher technophilen Kinder orientieren. Schließlich findet man, wie bei anderen Konsumprodukten auch, einen Reputationseffekt. Dieser führt dazu, dass ein Kunde (4) die Auswahlentscheidungen seines sozialen Umfelds imitiert, um einem latent existierenden Gruppenzwang zu entsprechen. Gerade diese Imitation wird dafür verantwortlich gemacht, dass sich reale Märkte häufig komplex und unberechenbar verhalten (vgl. [Bonabeau 2004]).

Die Wirkung von Netzwerkeffekten setzt dann ein, wenn sich aus den beschriebenen Einflüssen ein zusätzlicher Nutzen für ein Produkt bildet, der für die Entscheidung des jeweiligen Individuums eine relevante Größe darstellt und diese somit beeinflusst oder sogar bestimmt. Da diese Schwelle für jeden Kunden unterschiedlich ausgeprägt sein kann, spricht man in der wissenschaftlichen Literatur von einer individuellen kritischen Masse (vgl. [Liehr 2005], Kap. B.3.3) entscheidungsrelevanter Faktoren, z. B. der Anzahl Nachbarn, die Kunden bei einem bestimmten Netzbetreiber sind. Kommt es zufällig (oder durch geeignete Marketingmaßnahmen) zu einer hohen Marktdurchdringung eines Anbieters in einer lokalen Nachbarschaft wie z. B. einem Nischenmarkt, so kann diese Ansammlung als Brückenkopf fungieren, von dem aus sich ein Anbieter im Netzwerk weiter verbreitet (vgl. [Moore 2002]). Aus Anbietersicht stellen solche Netzwerkeffekte dynamische Wettbewerbsvorteile dar. Erfolgen durch Netzwerkeffekte beeinflusste Entscheidungen verschiedener Kunden in Abhängigkeit zueinander, nennt man die resultierende Marktentwicklung auch den Mitläufereffekt (im Englischen „bandwagon effects“, vgl. [Rohlf 2005]): Weil sich mit jedem zusätzlichen Kunden abermals die Wettbewerbssituation eines Anbieters verbessert, steigt somit auch wiederum die Wahrscheinlichkeit, dass dieser Anbieter zusätzliche Kunden gewinnen kann.

2.2. Strategien und Steuerungsmechanismen der Preisgestaltung im Mobilfunk

Die wissenschaftliche Aufarbeitung der Preisgestaltung im Telekommunikationsbereich hat eine lange Tradition, z. B. befasst sich bereits [Neumann 1984] mit diesem Thema, damals allerdings noch im von der Deutschen Bundespost als monopolistischem Staatsunternehmen bedienten deutschen Festnetzmarkt. Die Liberalisierung dieses Marktes kurz vor der Jahrtausendwende (vgl. z. B. [Gerpott 1998], Kap. 2.3) hat die Marktstrukturen seitdem aber massiv verändert, konkurrierende Anbieter hervorgebracht und damit auch neue Anforderungen an die Preisgestaltung im Wettbewerb gestellt (vgl. [Gerpott 1998], Kap. 6.1).

Die Etablierung des Mobilfunks als neue Produkt- und Netztechnologie hat zudem differenzierte Methoden der Produkt- und Preisgestaltung ermöglicht. In diesem Zuge entstandene neue betriebswirtschaftliche Entscheidungsprobleme werden im Folgenden herausgearbeitet und später im Rahmen der Fallstudien in Kapitel 8 exemplarisch adressiert.

Der Erfolg eines Mobilfunkunternehmens wird markt- und damit umsatzseitig von drei Größen bestimmt: der Kundenanzahl, dem durchschnittlichen Kundenumsatz („ARPU“, vgl. [Gruber 2005], Kap 2.5.1) sowie der Abwanderungsquote („Churn“-Rate). Da das angebotene Produkt „Mobilfunktelefonie“ weitgehend standardisiert ist und sich kaum zwischen verschiedenen Anbietern unterscheidet (vgl. [Gruber 2005], S. 39), bleibt den Anbietern als Einflussmöglichkeit für den Erfolg lediglich die Tarif- bzw. Preisgestaltung übrig. Das Entscheidungsproblem, diese Stellgrößen der Preisgestaltung so zu orchestrieren, dass die genannten Erfolgsfaktoren zu einem hohen und dauerhaften Umsatz führen, ist hochgradig komplex und von der Theorie noch wenig erschlossen (vgl. [Gruber 2005], S. 5). Speziell nichtlinear bepreiste Tarife sind insbesondere bei heterogenem Nutzungsverhalten nur schwer optimal zu bepreisen (vgl. [Pohl und Schmich 2001]). Es liegt aber auf der Hand, dass Mobilfunkunternehmen durch eine geschickte Preisgestaltung im Vergleich zur Konkurrenz die Voraussetzungen für ein profitables Umsatzwachstum schaffen können. Zumindest lässt sich in einem kompetitiven Marktumfeld auf diesem Wege eine Erosion des ARPU und der Kundenzahlen verhindern (vgl. [Capgemini 2007]).

Die skizzierte Situation der Mobilfunkunternehmen ist ein typischer Ausgangspunkt für den Einsatz von Verfahren des Operations Research (OR). Im weiteren Verlauf dieser Arbeit werden entsprechend auch geeignete OR-Verfahren für eine wettbewerbsorientierte Preisbestimmung auf Basis einer agentenbasierten Simulation entwickelt und angewendet. Im realen Markt begegnen die Anbieter diesem schwierigen Problem jedoch weitgehend mit methodisch deutlich weniger fortschrittlichen Ansätzen. Übliche strategische Stoßrichtung ist die exzessive Differenzierung der Preise mit vielen unterschiedlichen Tarifstrukturen (vgl. [Kreye 2005], Kap. 1), die zum einen jedem Kunden ein passgenaues Angebot bieten und zum anderen jedes Angebot der konkurrierenden Anbieter kontern sollen. Mit diesem Instrumentarium wird versucht, Kunden zu gewinnen und möglichst lange zu halten. Dadurch können die Anbieter sowohl einen stabilen und dauerhaften Umsatz sicherstellen als auch sich einen Kundenzugang für mögliches Cross- und Up-Selling erhalten (vgl. [Pohl und Schmich 2001]).

Da im Mobilfunk kontinuierlich (in der Regel monatlich) wiederkehrende Transaktionen üblich sind, ist auch die Kundenbindung (gemessen über die Churn-Rate) ein entscheidender wirtschaftlicher Faktor. Die Kundenbindung können die Anbieter beeinflussen, indem sie die Kundenzufriedenheit erhöhen oder auch positive oder negative Abwanderungsbarrieren aufstellen. Bei den positiven Abwanderungsbarrieren sind vor allem Community-Rabatte und klassische Bonusprogramme verbreitet, diese erhöhen die Attraktivität des aktuellen Anbieters eines Kunden. Negative Abwanderungsbarrieren (vgl. auch [Gruber 2005], Kap. 5.3.3 und [Rams 2001]) hingegen reduzieren die Attraktivität eines Anbieterwechsels, typischerweise durch eine vertragliche (vgl. [Pohl und Schmich 2001]) oder technische Bindung der Kunden. Zu den vertraglichen Bindungen zählen Mindestver-

tragslaufzeiten (bei Vertragstarifen sind auf dem deutschen Mobilfunkmarkt 24 Monaten üblich, vgl. [Stingel 2008], S. 2) oder Kündigungsgebühren. Bei den technischen Bindungen sind vor allem das sog. SIM-Locking, inkompatible Endgeräte aufgrund unterschiedlicher Frequenzbänder bei verschiedenen Anbietern oder eine erschwerte Rufnummernmitnahme zu nennen.

Da sich Community-Rabatte bisher kaum abseits des Mobilfunks etablieren konnten, sei dieses Instrument des Preismanagements hier näher charakterisiert. Community-Rabatte sind eine Ausprägung der Preisdifferenzierung (vgl. [Klein und Steinhardt 2008], Kap. 2, [Tacke 1989], Kap. 2.1, oder [Simon und Fassnacht 2006], Kap. 9.3.2), bei der ein im Kern identisches Produkt an verschiedene Kunden zu unterschiedlichen Preisen mit dem Ziel der Absatz- und Erlössteigerung verkauft wird. Genauer spricht man von einer segmentspezifischen Preisdifferenzierung dritten Grades, wobei die Segmente für jeden Konsumenten unterschiedlich anhand seiner individuellen Nachbarschaft abgegrenzt sind. Arbitrage ist hier nicht möglich, da das Identifikationskriterium für die Nachbarschaft in der Regel durch die Gesprächspartner der Person fest vorgegeben ist. Demnach handelt es sich hierbei um eine personenbezogene Preisdifferenzierung (vgl. [Homburg und Krohmer 2009], Kap. 12.3.1.2.2).

2.3. Ziele und Mechanismen der Preisoptimierung

Die Preisgestaltung ist eine wichtige Stellgröße eines Unternehmens, um nachhaltiges, profitables Wachstum zu erzielen. [Ng 2008] (S. 6) listet verschiedene praktische Ausprägungen dieser allgemeinen Zielsetzung auf, die sich auf Kriterien wie die Erlösmaximierung, die Adressierung von Kundenbedürfnissen oder auch auf die Interaktion mit Wettbewerbern beziehen. In diesem Spannungsfeld zwischen häufig nicht kohärenten – bis hin zu sich gegenseitig ausschließenden – Zielen muss ein Unternehmen entscheiden, welche strategischen Prioritäten es setzt.

Im Falle eines Mobilfunknetzbetreibers (MNO) stellt die *Umsatzmaximierung* sicherlich die primäre Zielsetzung der Preisgestaltung dar. Da Anbieter im Mobilfunk, wie in Kapitel 2.1.1 ausgeführt, hauptsächlich mit quasi-fixen Kosten konfrontiert sind, wird hierbei parallel zum Umsatz auch näherungsweise der erzielte Gewinn maximiert.

Um die Nachhaltigkeit des Wirtschaftens sicherzustellen, sind MNOs außerdem häufig daran interessiert, einen möglichst *hohen Marktanteil* dauerhaft zu erhalten. Bedingt durch vergleichbare Produkte und einen intensiven Wettbewerb im Markt ist die Abwanderungsrate der Bestandskunden (Churn-Rate) ein dieser Zielsetzung entgegenstehendes Problem. Dieses wird zum einen durch die Gewinnung von Neukunden adressiert, entweder zulasten der konkurrierenden Wettbewerber (Kundenabwerbung) oder durch die Erschließung neuer Kundengruppen (Marktentwicklung). Zum anderen ist aber auch die Bindung existierender Kunden an das Unternehmen ein wichtiger Aspekt, z. B. durch sogenannte Lock-in-Maßnahmen, die einen Wechsel zur Konkurrenz unattraktiver machen. Da die Kundenbasis eine notwendige Voraussetzung für zukünftige Umsätze ist, stellt die Erhaltung des Kundenstamms eine Absicherung für die wirtschaftliche unwägbare Zukunft dar.

Aus finanzieller wie auch operativer Sicht ist zudem die *Glättung von Nachfrageschwankungen* ein wünschenswertes Ziel. Durch gezielte und differenzierte Preisanreize wird hierbei eine geringere Dimensionierung neuer Netzkapazitäten ermöglicht bzw. die bessere Ausnutzung vorhandener Kapazitäten bewirkt.

Mögliche Mechanismen der Preisgestaltung, um die genannten Ziele zu erreichen, lassen sich in kosten-, wettbewerbs- und nachfrageorientierte Ansätze unterteilen (vgl. [Avlonitis und Indounas 2005] oder [Homburg und Krohmer 2009], Kap. 12.3).

Für einen Mobilfunknetzbetreiber scheiden *kostenbasierte* Methoden, die den Stückpreis in Abhängigkeit der zur Erstellung des Produkts notwendigen Stückkosten bestimmen, weitgehend aus. Die Kostenstruktur eines MNO besteht wie bereits ausgeführt nur zu einem relativ geringen Teil aus direkt zurechenbaren variablen Kosten. Die Grenzkosten einer produzierten Mobilfunkminute sind deshalb (außerhalb selten vorkommender Netzengpässe) vernachlässigbar und können nicht als Ausgangspunkt für eine Preisentscheidung dienen. Eine alternativ mögliche Vollkostenbetrachtung setzt die Aufteilung der Fixkosten auf eine a priori nur schwer einschätzbare Absatzmenge voraus und im Falle mehrerer Produkte (wie Sprach- und Datenübertragung, ggf. noch je mit unterschiedlichen Tarifen) ist eine Aufteilung der Kosten zwischen den Produkten vergleichsweise beliebig. Es verbleibt die Möglichkeit für den Anbieter, ausgehend von den variablen Kosten einen produktspezifischen Aufschlag zur Deckung der Fixkosten zu verlangen, der sich an der Nachfrageelastizität orientiert (vgl. [Haucap 2003]). Die Basis der Kosten tritt dann aber klar in den Hintergrund.

Marktadäquater erscheint der Ansatz, die Preise *wettbewerbsbasiert* in Relation zu den Preisen der konkurrierenden Anbieter festzusetzen. Dies ist insbesondere in einem wettbewerbsintensiven Markt wie dem Mobilfunk praktikabel, da Mobilfunkminuten ein generisches Produkt darstellen, das zwischen den einzelnen Anbietern weitgehend substituierbar ist.

Für einzelne Tarife aus dem Portfolio eines MNO erscheint auch eine *nachfragebasierte* Preissteuerung realistisch, bei welcher der Preis anhand einer erwarteten Nachfrage festgesetzt oder anhand einer eingetretenen Nachfrage dynamisch angepasst wird. Voraussetzung hierfür ist allerdings im Gegensatz zur wettbewerbsbasierten Preissteuerung, dass Kunden nicht problemlos auf Tarife der Konkurrenz umschwenken können. Dies kann durch überlegene Produktcharakteristika oder andere Kundenbindungsmaßnahmen (vgl. Kap. 2.2) sichergestellt werden.

2.4. Bisherige Ansätze zur Preisoptimierung in der Telekommunikation

Wissenschaftliche Arbeiten zur Preisoptimierung in der Telekommunikation finden sich bereits zu der Zeit, als diese noch mit Festnetztelefonie gleichgesetzt und der Markt durch staatliche Monopolisten dominiert wurde. Damals waren die Zielsetzungen der Optimierung eher wohlfahrtsökonomischer Natur, während mit der weiteren Öffnung der Märkte für konkurrierende Unternehmen und der Einführung des Mobilfunks vermehrt betriebswirtschaftliche Fragestellungen der Umsatz- und Gewinnmaximierung Einzug gehalten haben.

Im Folgenden findet sich eine Auswahl relevanter wissenschaftlicher Arbeiten zur Preisoptimierung in der Telekommunikation, die sowohl die Entwicklung der Fragestellungen als auch der verwendeten Methodiken im Zeitverlauf widerspiegelt. Unterschieden wird bei der Vorstellung zwischen klassischen Optimierungsansätzen und simulationsbasierten Ansätzen. Die klassische Optimierung bedient sich in dieser Klassifikation der etablierten Methoden aus dem Operations Research, wie z. B. der linearen oder ganzzahligen Optimierung (vgl. [Domschke und Drexl 2007], Kap. 2 bzw. Kap. 6), und wendet diese Verfahren auf vergleichsweise einfache Modellierungen von Telekommunikationsmärkten an. Simulationsbasierte Ansätze hingegen adressieren komplexere Modelle, bei denen die für die klassische Optimierung notwendigen Vereinfachungen im konkreten Anwendungsfall nicht akzeptiert werden können. Insbesondere tritt dies häufig bei stochastischen Einflüssen sowie bei dynamischen Wechselwirkungen innerhalb des Modells auf. Die Simulation erlaubt dann sowohl die Analyse des modellierten Systemverhaltens als auch eine Optimierung auf Basis der Simulation (vgl. auch Kap. 5).

2.4.1. Klassische Optimierungsansätze

[Späth 1995] betrachtet einen Markt für Festnetztelefonie, auf dem ein Anbieter als Monopolist das Ziel einer langfristigen Gewinnmaximierung unter Berücksichtigung von Investitionskosten und Erlösen hat. Die Kunden sind mangels Konkurrenz im Markt an den Netzanbieter gebunden. Hauptaugenmerk legt der Autor auf die Frage, mit welchen Preisstrategien die Nachfragebedürfnisse der Kunden befriedigt werden können, und wie eine gezielte Steuerung der Nachfrage zu einer hohen Kapazitätsauslastung führen kann. Zentrales Steuerungsinstrument für den Anbieter ist hierbei der Preis (aufgeteilt in Grundgebühren und nutzungsabhängige Gebühren), welcher sich über einen betrachteten Planungshorizont dynamisch entwickelt. Im Rahmen der Analyse der Diffusionsgeschwindigkeit berücksichtigt Späth auch Netzwerkeffekte in aggregierter Form. Für die Lösung seines Optimierungsproblems wendet er einen Ansatz der dynamischen Programmierung an. Späth kommt zu dem Ergebnis, dass über den Zeitverlauf moderat steigende Nutzungspreise in Kombination mit einer aggressiveren Penetrationsstrategie bei den Grundgebühren für den Anbieter den größtmöglichen langfristigen Gewinn bieten.

[Haase et al. 1998] untersuchen Möglichkeiten zur Preisdifferenzierung bei „Call-by-Call“-Tarifen im Festnetz und stellen hierfür ein gemischt-ganzzahliges Optimierungsmodell vor. Kunden können damit den preisgünstigsten Anbieter für ein gegebenes Nutzungsverhalten ermitteln, während Anbieter eigene Tarife im Kontext des Angebots der Konkurrenz überprüfen und Szenarioanalysen durchführen können. Verschiedene Fallbeispiele zeigen unter anderem, dass Kunden durch mengenbezogene Preisdifferenzierung an einen Anbieter gebunden werden können.

[Skiera 1999] (Kap. 4) beschreibt einen allgemeinen Markt für Dienstleistungen und bezieht sich hierbei häufig auf den Mobilfunkmarkt als typisches Beispiel. Der Autor betrachtet verschiedene Möglichkeiten der mengenbezogenen Preisdifferenzierung und zeigt, wie diese in üblichen Tarifstrukturen abgebildet werden können. Zur Optimierung des Gewinns eines Anbieters unter der Annahme eines preisabhängigen Nachfrageprofils der Kunden formuliert der Autor verschiedene nichtlineare Optimierungsmodelle und analysiert, welche

Tariftypen sich für die Gewinnmaximierung eignen. In [Skiera 1998] befasst sich der Autor kritisch mit der Problematik, dass derartige Optimierungen entscheidend von dem unterstellten Nutzungsprofil abhängen. Er schlägt deshalb vor, das Nutzungsprofil als Variable in der Optimierung zu betrachten. Auf diesem Weg sollen für vorgegebene Tarife die Nutzungsszenarien ermittelt werden, in denen der Tarif gegenüber allen anderen Tarifen vorteilhaft ist.

[Schön-Peterson 2003] befasst sich mit dem deregulierten deutschen Festnetzmarkt und bietet eine Modellierung sowie Lösungsoptionen zur optimalen Tarifgestaltung. Sie berücksichtigt sowohl klassische Tarife mit Grund- und nutzungsabhängigen Preisen als auch fortgeschrittene Tarifarten mit Mengenrabatten oder rabattierten Rufnummern. Zur exakten Lösung des formulierten gemischt-binären linearen Optimierungsproblems können prinzipiell exakte Standardverfahren verwendet werden, für größere Problemklassen zeigt Schön-Peterson aber auch geeignete Heuristiken.

[Cha et al. 2008] gehen davon aus, dass ein Mobilfunkanbieter seine Preise senken muss, zum Beispiel aufgrund regulatorischer Anforderungen oder aufgrund dessen Wettbewerbssituation. Die Autoren schätzen mit einem ökonometrischen Modell das individuelle Nutzungsverhalten der Kunden unter Berücksichtigung der gegenseitigen Abhängigkeiten zwischen niedrigeren Preisen und einer potenziell höheren Nutzung. Es wird gezeigt, welche Auswirkung die zu treffenden Preismaßnahmen auf die Nutzung und den resultierenden Umsatz in verschiedenen Alterssegmenten hätten. Mit diesem Werkzeug ausgestattet sollen Anbieter notwendige Preismaßnahmen unter Berücksichtigung altersgruppen- und tarifspezifischer Preiselastizitäten so differenziert durchführen können, dass ein optimaler Umsatz erzielt wird.

[Samanta et al. 2009] erstellen ein funktionales Umsatz- und Kostenmodell für einen Mobilfunknetzbetreiber und leiten damit die gewinnmaximale Kombination aus Grund- und Nutzungsgebühren her. Zentrales Instrument ist eine auf Basis von Daten des indischen Mobilfunkproviders BSNL approximierte preisabhängige Nachfragefunktion bzgl. des Mobilfunkzugangs und der darüber abgewickelten Nutzung. Im Ergebnis empfehlen die Autoren, zur Maximierung des Gewinns die Grundgebühren ohne Aufschlag lediglich an den Kosten der Bereitstellung des Mobilfunkzugangs zu orientieren. So sollen eine hohe Marktdurchdringung erreicht und gleichzeitig über die Nutzungsgebühren zusätzliche Umsätze abgeschöpft werden.

2.4.2. Simulationsbasierte Ansätze

[Tacke 1989] (Kap. 3.4 und Kap 5.3) untersucht einen Telekommunikationstarif mit Grund- und nutzungsabhängigen Gebühren als Alternative bzw. Ergänzung zum existierenden Tarifwerk eines Anbieters. In einer Simulation werden die Gewinne berechnet, die sich aus einem festgelegten Preisschema und der resultierenden Nachfrage der Kunden ergeben. Die preisabhängige individuelle Nachfrage der simulierten Marktteilnehmer entspricht dabei dem empirisch ermittelten Nachfrageverhalten einer Testgruppe. Durch Variation der Preisstruktur wird ein für den Anbieter gewinnmaximaler Tarif gesucht.

[Gerolamo et al. 2004] simulieren die Entwicklung eines kompetitiven Telekommunikationsmarktes. Verschiedene Typen von Konsumenten entscheiden über den Abschluss eines Ver-

trags bei einem Serviceprovider. Neben Preis und Servicequalität stellt insbesondere die Marktdurchdringung in der Nachbarschaft der Kunden ein zentrales und differenzierendes Entscheidungskriterium dar. Näher analysiert werden unter anderem Auswirkungen auf das Wechselverhalten der Kunden sowie die Voraussetzungen für statische bzw. eher labile Marktverhältnisse.

[Schade et al. 2009] analysieren den Markteintritt eines neuen Anbieters auf dem deutschen Mobilfunkmarkt mithilfe eines agentenbasierten Simulationsmodells. Anhand realistischer Nutzerprofile werden insbesondere aus verbilligten netzinternen Gesprächen resultierende Netzwerkeffekte näher untersucht, die einen neuen Wettbewerber gegenüber etablierten Anbietern benachteiligen. Im Ergebnis kristallisiert sich ein aggressiver Discountpreis als einzig realistische Preisstrategie für die Etablierung des neuen Anbieters auf dem Markt heraus.

2.4.3. Abgrenzung der vorliegenden Arbeit

In der breiten Masse der gezeigten relevanten Forschungsarbeiten zur Preisoptimierung im Telekommunikationsmarkt wird ein Nutzungs- und somit Entscheidungsverhalten der Kunden angenommen, das unabhängig vom Nutzungsverhalten anderer Kunden ist (vgl. [Tacke 1989], [Haase et al. 1998], [Skiera 1999], [Schön-Peterson 2003], [Cha et al. 2008] und [Samanta et al. 2009]). Die im realen Markt beobachteten Netzwerkeffekte lassen sich mit einer solchen Modellierung entsprechend nicht berücksichtigen.

[Späth 1995] (S. 31) sieht zwar den Zusammenhang, dass einzelne Kunden ihre individuelle Nachfrageentscheidung von einer bestimmten Anzahl für sie relevanter anderer Kunden abhängig machen (vergleichbar zu dem in der vorliegenden Arbeit vorgestellten Konzept der Nachbarschaft). Er bezieht diesen Aspekt in seiner Modellierung aber nicht ein. Die Berücksichtigung von Netzwerkeffekten erfolgt deshalb nur in aggregierter Form über die Gesamtanzahl der Kunden zum jeweiligen Zeitpunkt, der sogenannten „installierten Basis“. Neben dem Preis und den genannten Netzwerkeffekten gehen aber keine weiteren Einflussfaktoren wie z. B. die Produktqualität in die Nachfrageentscheidung mit ein.

Explizit berücksichtigt werden Netzwerkeffekte hingegen von [Gerolamo et al. 2004] und [Schade et al. 2009]. Erstgenannte Arbeit zielt mit der Simulation aber nicht auf die quantitative Optimierung von Preisen ab, sondern betrachtet lediglich deren qualitative Auswirkungen auf den Gesamtmarkt. Zweitgenannte Arbeit stellt ein agentenbasiertes Simulationsmodell des Mobilfunkmarktes vor, das Ähnlichkeiten zu dem in Kapitel 4 konstruierten Modell aufweist. Die Autoren gehen jedoch nicht soweit, die Simulation auch für eine algorithmische Optimierung zu verwenden, sondern probieren lediglich verschiedene Parametrisierungen der Simulation aus und leiten hieraus Schlüsse für die Tarifoptimierung im realen Markt ab.

Die vorliegende Arbeit stellt ausgehend von [Schade et al. 2009] die nächste methodische Entwicklungsstufe der Anwendung einer agentenbasierten Simulation speziell auch im Kontext eines Mobilfunkmarktes dar. Die Simulation wird hierbei nicht mehr als Instrument für Einzelexperimente verwendet, sondern in einen übergeordneten simulationsbasierten Optimierungsalgorithmus eingebettet und dort als Bewertungsfunktion bezüglich eines konkreten Preismodells (Parametrisierung der Simulation) verwendet. Mit diesem Ansatz

lassen sich, wie in den folgenden Kapiteln gezeigt wird, unter Berücksichtigung des individuellen, heterogenen Entscheidungsverhaltens der Marktteure und der resultierenden Netzwerkeffekte die Preise eines Mobilfunkanbieters optimieren.

3. Grundlagen und Anwendungen der agentenbasierten Simulation

Die agentenbasierte Simulation (ABS) ist ein Werkzeug, das immer größere Popularität in der akademischen Forschung gewinnt. Beispielsweise befasst sich das Journal of Artificial Societies and Social Simulation (JASSS) dediziert mit dieser Thematik. In den Wirtschaftswissenschaften ist dieses Konzept aber bisher weniger bekannt, vereinzelte relevante Artikel finden sich verstreut über eine Vielzahl unterschiedlicher Publikationen. Deshalb soll diese Arbeit grundlegend die ABS im Kontext der Wirtschaftswissenschaften aufarbeiten und damit auch als Werkzeug des Operations Research positionieren. Eine mit diesem Kapitel in engem inhaltlichen Zusammenhang stehende Diskussion der Grundlagen der ABS zur Analyse und Lösung betriebswirtschaftlicher Entscheidungsprobleme findet sich bereits bei [Deckert und Klein 2010] veröffentlicht.

Der weitere Verlauf dieses Kapitels gliedert sich in drei Schwerpunkte: In Kapitel 3.1 werden zunächst die grundlegende Methodik der ABS vorgestellt, ihre Kernelemente analysiert und geeignete Anwendungsfelder skizziert. Anschließend bietet Kapitel 3.2 einen breiten Überblick betriebswirtschaftlicher Anwendungen entlang verschiedener Wirtschaftszweige und Anwendungskategorien. In Kapitel 3.3 wird abschließend der Anwendungsprozess einer ABS mit einem Fokus auf gängigen Umsetzungsoptionen zur Erstellung eines agentenbasierten Modells beschrieben.

Pionierarbeiten auf dem Gebiet der ABS haben [Schelling 1978], [Axelrod 1984] sowie [Epstein und Axtell 1996] geleistet. In der Folge dieser Publikationen hat sich ein vielschichtiges Forschungsfeld im Schnittbereich zwischen der Ökonomie (vgl. [Tesfatsion 2002]) und der Soziologie (vgl. [Gilbert 2007]) etabliert. Wie die vorliegende Arbeit zeigt, wird die ABS jedoch auch zunehmend zur Lösung betriebswirtschaftlicher Entscheidungsprobleme genutzt. Dies ist vor allem darauf zurückzuführen, dass in der betrieblichen Praxis zunehmend Systeme entstehen und zu analysieren sind, die durch die Aktionen eigenständig agierender Akteure geprägt werden. Beispiele hierfür sind die Kooperation von Unternehmen in Wertschöpfungsnetzen oder durch Netzwerkeffekte geprägte Märkte für innovative Produkte. Ziel dieses Kapitels ist es, einen Überblick entsprechender Anwendungen zu geben.

3.1. Agentenbasierte Simulation

Der „AgentLink agent hype cycle“¹⁹ in [Luck et al. 2005] (Kap. 6.2.2) beschreibt auf der Grundlage einer Befragung von Experten aus Industrie und Wissenschaft die ABS als eine Technologie auf dem Weg zum etablierten produktiven Einsatz. Eine eingehende Recherche wirtschaftswissenschaftlicher Publikationen zeigt aber ein differenzierteres Bild, demnach befindet sich das Forschungsfeld noch stark in der Explorationsphase. Viele verschiedene

¹⁹ Der „Hype cycle“ ist ein ursprünglich von Gartner entwickeltes Konzept zur Darstellung des Reifegrads einer Technologie, siehe <http://www.gartner.com/pages/story.php.id.8795.s.8.jsp>, abgerufen am 28. Februar 2009.

wissenschaftliche Ansätze der ABS adressieren ein breites Spektrum an Fragestellungen aus unterschiedlichen Fachgebieten (für Übersichten vgl. [Heath et al. 2009] oder [Meyer et al. 2009]), wobei es wenige Übereinstimmungen hinsichtlich Methodik und Vorgehen gibt (vgl. [Axelrod 2006], [Richiardi et al. 2006] oder [McKean et al. 2008]). Allgemein herrscht eine eher geringe Nachvollziehbarkeit der Ergebnisse agentenbasierter Simulationsstudien vor, da deren Modellierungs- und Implementierungsdetails nur selten hinreichend diskutiert werden. [Heath et al. 2009] belegen sogar, dass diese mangelnde Transparenz bei Arbeiten mit betriebswirtschaftlichem Hintergrund besonders stark ausgeprägt ist. Als Konsequenz bauen Arbeiten von unterschiedlichen Autoren auch nur selten aufeinander auf (vgl. [Janssen et al. 2008]).

Um dem Leser einen Einblick in die Möglichkeiten und Grenzen des Werkzeugs ABS zu geben, werden in diesem Kapitel deren zentrale Bausteine sukzessive vorgestellt und abschließend an einem Beispiel ausführlicher diskutiert. Es sei hierbei explizit auf die Simulation als ein eigenständiges Werkzeug der agentenbasierten Forschung eingeschränkt. Multiagentensysteme (MAS, siehe [Ferber 1999], [Weiss 1999] oder [Wooldridge 2009]) bilden hierzu den methodologischen Überbau, gehen aber in der Konzeption und der Modellierung der Agenten häufig weit über die Erfordernisse einer ABS hinaus. Dieses komplexere Agentenverständnis findet seine Anwendung z. B. in einer Vielzahl von Ansätzen der agentenorientierten Softwareentwicklung (siehe [Bergenti et al. 2004] oder auch [Cervenka und Trencansky 2007]), die zum Ziel haben, ein Problem im realen System mittels dezentral agierender Agenten, häufig mit Methoden der verteilten künstlichen Intelligenz, zu lösen.

3.1.1. Einordnung und Abgrenzung zu klassischen simulationsbasierten Ansätzen

Die ABS basiert, wie andere Simulationen auch, auf der Abbildung eines realen Systems bzw. dessen relevanter Komponenten in einem Simulationsmodell. Zur Durchführung eines Simulationsexperiments wird dabei der im Modell eingebettete zeit- oder ereignisgesteuerte Ablaufalgorithmus ausgeführt, der praktisch die innere Mechanik der Simulation darstellt. Die dynamische Entwicklung des Systems wird in der Regel auf Basis von Perioden erfasst, wobei jeweils ein Anfangszustand zu Beginn der Periode in einen Endzustand am Ende der Periode überführt wird. Die entsprechende Transformation erfolgt, indem Agenten innerhalb der Periode Aktionen durchführen. Zu diesem Zweck verfügt jeder Agent über ein eigenes Verhaltensmodell, das sowohl die Generierung der möglichen Aktionen (Alternativen) an sich als auch deren Bewertung und Auswahl beschreibt. Werden dabei Informationen über den Zustand anderer Agenten berücksichtigt, so ergibt sich eine Interaktion. Durch Aggregation der agentenspezifischen Aktionen resultiert nach jeder Periode der neue Simulationszustand. Neben allgemeinen Parametern, die das System als solches sowie mögliche Umweltlagen beschreiben, sind auch die Verhaltensmodelle durch geeignete Parameter auszugestalten. Mit jeder zu überprüfenden Kombination dieser Parameter werden unter Einsatz eines Simulators, d. h. eines Computerprogramms, Simulationsläufe durchgeführt. Für Parameter, die stochastischen Einflüssen unterliegen, wird dabei in jedem Simulationslauf eine Stichprobe entsprechend der unterstellten Wahrscheinlichkeitsverteilung gezogen. Die ABS ist damit ein Spezialfall der diskreten Simulation (vgl. Abbildung

17), bei der Systeme grundsätzlich ihren Zustand nur zu bestimmten (diskreten) Zeitpunkten ändern.

Ein Anwendungsbeispiel der ABS stellt die Markteinführung eines Produkts dar, für das die Anzahl der neu gewonnenen Kunden am Ende eines Planungshorizonts bestimmt werden soll. Dabei repräsentiert die Menge der Agenten die Menge der potenziellen Kunden. In jeder Periode können Agenten, die das Produkt bisher nicht besitzen, über den möglichen Erwerb entscheiden. Um mögliche vernetzte Wirkungszusammenhänge zu berücksichtigen, kann in ihre Entscheidung etwa einfließen, wie viele andere Kunden das Produkt bereits gekauft haben.

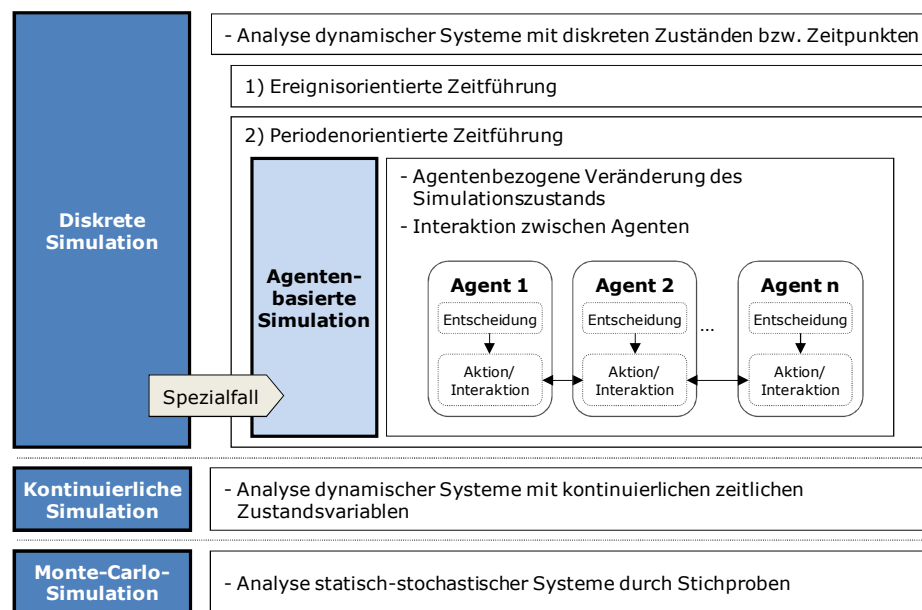


Abbildung 17: ABS im Kontext klassischer simulationsbasierter Ansätze

Quelle: eigene Darstellung

Eine alternative Form der diskreten Simulation ergibt sich bei einer ereignisorientierten Zeitführung, bei der ein Übergang von einem Zustand des Systems zu einem anderen durch das Eintreten sog. Ereignisse erfolgt. Die betrachteten Elemente des Systems agieren dabei aber nicht autark im Sinne von Agenten. In der betriebswirtschaftlichen Planung werden entsprechende Simulationen vor allem zur Analyse von Warteschlangensystemen eingesetzt, bei denen das Verhalten unter Unsicherheit Gegenstand der Untersuchung ist und Zufallseinflüsse durch stochastische Zwischenankunftszeiten abgebildet werden. Sowohl bei der ereignisorientierten als auch bei der periodenorientierten Zeitführung werden Änderungen des Simulationszustands durch die Elemente des Systems propagiert (vgl. [Klügl 2000], S. 42) und resultieren dann in einem neuen Simulationszustand.

Neben der diskreten Simulation existieren die kontinuierliche und die Monte-Carlo-Simulation (vgl. z. B. [Domschke und Drexl 2007], Kap. 10.1). Die kontinuierliche Simulation (wie von „System Dynamics“-Modellen bekannt, siehe z. B. [Sterman 2000] oder [Bossel 2004]) verwendet man vor allem zur Simulation dynamischer deterministischer Systeme. Auch sie versucht wie die ABS, komplexe Wirkungszusammenhänge, die analytisch nicht zu erfassen sind, nachzubilden. Dabei wird die Änderung der Systemzustände typischerweise durch

eine oder mehrere Differenzialgleichungen abgebildet. Mögliche Anwendungen sind das Testen von Preiswirkungen in einem nichtlinearen Marktmodell oder die Bilanzfortschreibung in Abhängigkeit von bestimmten Investitionsmaßnahmen. Im Beispiel für die Markteinführung eines Produkts könnte die Anzahl der Kunden zu einem bestimmten Zeitpunkt t etwa durch die Gleichung $\text{Kunden}(t+\partial t) = \text{Kunden}(t) + \partial \cdot \text{Neukundenrate}(t+\partial t)$ beschrieben werden. Sie enthält einerseits Bestandsgrößen, die das Niveau relevanter Elemente des Systems zu einem bestimmten Zeitpunkt ausdrücken ($\text{Kunden}(t)$) und andererseits Flussgrößen, welche die relative Änderung je Zeiteinheit angeben ($\text{Neukundenrate}(t)$). Man erkennt, dass die Modellierung im Gegensatz zur ABS jedoch auf einer Makroebene erfolgt, sodass sich zahlreiche Effekte, die im Rahmen einer ABS sichtbar werden, nur schwierig nachbilden lassen (vgl. [Parunak et al. 1998]). Die Monte-Carlo-Simulation dient schließlich der Simulation statischer stochastischer Systeme durch Stichprobenexperimente und ist damit grundsätzlich nicht mit der ABS vergleichbar.

3.1.2. Agenten und deren Verhalten

Unter dem Schlagwort „Agent“ findet sich in der Literatur eine Vielzahl möglicher Interpretationen und Konzepte (vgl. [Franklin und Graesser 1996]). Die wohl gebräuchlichste Definition stammt aus [Wooldridge und Jennings 1995], hiernach sind Agenten autonom (verhalten sich unabhängig von einer exogenen Intervention), interaktiv (tauschen sich mit anderen Agenten und der Umgebung aus), reaktiv (erfassen und reagieren auf die Einflüsse der Umgebung sowie anderer Agenten) und proaktiv (zeigen zielgerichtetes initiatives Verhalten). Besonders treffend für die weitere Betrachtung im Laufe dieser Arbeit erscheint jedoch die einfachere Definition von [Heath et al. 2009], nach der ein Agent schlicht eine abstrakte Repräsentation einer verteilten autonomen Entität ist. Die Agenten in einer ABS können stellvertretend für biologische oder physikalische Entitäten stehen, für soziale Gruppen (wie z. B. die Familie, ein Unternehmen) oder Institutionen (z. B. eine Behörde). Das grundsätzliche Verhalten von Agenten, das in der möglichen Durchführung einer Aktion und damit verbunden einer Interaktion mit anderen Agenten in jeder Periode der Simulation besteht, wird durch ein *Verhaltensmodell* festgelegt (vgl. z. B. [Klügl 2000], Kap. 4.1.3). Im Rahmen der Spezifikation des Verhaltensmodells sind folgende Aspekte zu adressieren:

1. Analyse/Auswertung des Simulationszustands
2. Generierung einer Menge agentenspezifischer Alternativen für eine Aktion
3. Auswahl einer Alternative auf Basis einer Entscheidungsregel
4. Aktion/Interaktion: agentenbezogene Veränderung des Simulationszustands

Das Handeln eines Agenten als Ausdruck seines Verhaltens innerhalb einer Periode (ein sog. Verhaltensschritt) lässt sich folgendermaßen beschreiben: Ausgehend vom aktuellen Simulationszustand erhebt ein Agent relevante Daten und wertet diese zur Generierung einer agentenspezifischen Menge von Aktionsalternativen aus (falls diese nicht schon statisch vorgegeben sind). Je nach Modell kann hierbei auch die Nullalternative, d. h. keine Aktion, enthalten sein. Die Auswahl einer der Alternativen stellt damit eine Entscheidungsvariable aus Sicht des Agenten dar. Durch Anwendung einer Entscheidungsregel auf Basis der die Alternative beschreibenden Attribute erfolgt zunächst die Bewertung der einzelnen

Alternativen und schließlich die Auswahl einer Alternative. Die damit ausgelöste Aktion des Agenten ändert den Zustand der Simulation, was wiederum die späteren Entscheidungen anderer Agenten beeinflussen kann.

Die Möglichkeiten zur Definition von Entscheidungsregeln sind vielfältig (vgl. [Klügl 2000], Kap. 3.3) und reichen von einer zufälligen Entscheidung bis hin zu komplexen Regelwerken zur Entscheidungsfindung. Im Falle statischen Verhaltens sind die Entscheidungsregeln fest vorgegeben, während diese bei dynamischem Verhalten im Laufe der Simulation angepasst werden können. Heterogenität im Verhalten der Agenten wird häufig durch eine geeignete individuelle Parametrisierung der Entscheidungsregeln erreicht. Oftmals liefern empirische Studien allerdings nur aggregierte Daten zum durchschnittlichen Verhalten von Individuen, die dann zur Abbildung einer realistischen Heterogenität je Agent adäquat variiert werden müssen.

Die Durchführung einer Aktion schließt oftmals auch die Interaktion mit anderen Agenten ein, z. B. durch den direkten oder indirekten Austausch von Informationen oder die Auflösung von Ressourcenkonflikten (vgl. [Axelrod und Cohen 1999], Kap. 3). Interessant wird die Interaktion insbesondere, wenn das kollektive Verhalten mehr darstellt als nur die schlichte Summe seiner Bestandteile. In [Russell und Norvig 2004] (Kap. 2.4) wird sehr anschaulich die Bandbreite der Facetten von Agentenverhalten dargestellt, ausgehend von Reaktionen auf einfache Zustandsveränderungen bis hin zu zielgerichtetem Verhalten und Lernen aus früheren Erfahrungen.

Die Zusammenführung aller Agentenaktionen einer Periode liefert die periodenbezogene Transformation des Simulationszustands (vgl. Abbildung 18). Die genaue Abfolge der Aktionen der Agenten untereinander muss dabei problemadäquat geregelt werden, übliche Ansätze sind eine vordefinierte statische Abfolge, eine je Periode zufällig gewählte Abfolge oder auch ein Verfahren, bei dem sich die Agenten um das Recht zur Aktion aktiv bewerben und dieses zugeteilt bekommen.

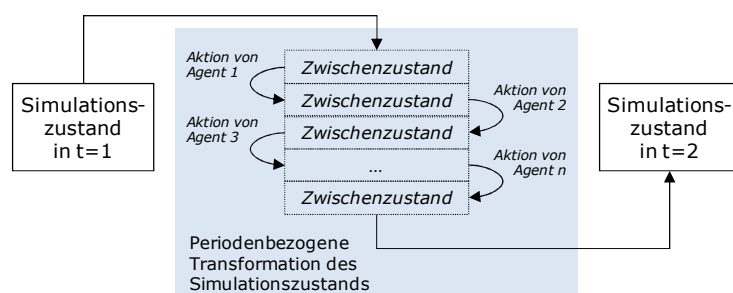


Abbildung 18: Transformation des Simulationszustands durch Agenten

Quelle: eigene Darstellung

Die Ableitung von Agentenverhalten aus einem realen System ist allgemein ein schwieriges Unterfangen, da selbst umfangreiche empirische Untersuchungen oft keine vollständige Beobachtung und Beschreibung der Entscheidungssituation von Individuen liefern. Für eine ABS ist es deshalb zielführend, Hypothesen zum individuellen Entscheidungsverhalten aufzustellen, diese in Entscheidungsregeln umzusetzen und die Ergebnisse der Simulation dann mit beobachtbaren Mustern aus der Realität zu vergleichen (vgl. [Grimm et al. 2005]).

Oftmals wird man in realen Systemen z. B. auf Aspekte begrenzter Rationalität bei der Entscheidungsfindung der handelnden Akteure stoßen. Menschen streben in der Regel nicht nach Optimalität, sondern nach subjektiv attraktiven oder zumindest zufriedenstellenden Lösungen (vgl. [Simon 1996]). Eine Vielzahl von Gründen kann hinter einem solchen Verhalten stehen, wie [Tesfatsion 2006] und [Darley und Outkin 2007] darstellen: asymmetrische Informationen, Annahmen auf Basis unvollständiger Informationen, die Anwendung von Heuristiken (vgl. [Bettman et al. 1991]), Verhaltensänderungen durch das Lernen aus vergangenen Erfahrungen, äußere Einflüsse wie z. B. soziale Normen oder auch die Verfolgung mittelbarer Ziele (z. B. bevorzugte Handelspartner, Marktmacht oder Betrug). In der Simulation gilt es letztendlich, die empirisch beobachteten Verhaltensweisen der Akteure durch das Verhalten der Agenten möglichst adäquat abzubilden.

Das Verhalten der Agenten definiert zwar die innere Mechanik der Simulation, die daraus resultierende Komplexität erschließt sich aber nicht bei einer statischen Modellbetrachtung, sondern wird erst beim Ablauf der Simulation deutlich. Die Beobachtung der sich dynamisch entwickelnden Strukturen eines solchen Simulationslaufs und die Interpretation der gewonnenen Ergebnisse sind entsprechend das eigentliche Ziel einer ABS (siehe [Marks 2006] und auch [Epstein und Axtell 1996], S. 16). Oft zeigen sich erst hierbei die vielschichtigen Implikationen, welche selbst durch einfaches Agentenverhalten oder generelle Modellannahmen ausgelöst wurden (vgl. [Simon 1996]).

3.1.3. Eignung und Anwendungsfelder

Simulationen sind als Werkzeug vor allem dann zweckdienlich, wenn ein Modell mit anderen weniger aufwendigen bzw. analytisch besser greifbaren Ansätzen nicht geeignet auswertbar ist. Das gilt insbesondere für die ABS, da die Modellierung des betrachteten Systems auf der Mikroebene der einzelnen Akteure ein aufwendiges Unterfangen darstellt und nur dann gerechtfertigt ist (vgl. [Parunak et al. 1998]), wenn zentrale Charakteristika des Systems durch die Besonderheiten der ABS adressiert werden können: Heterogenität der Akteure, Netzwerkeffekte und Emergenz (siehe auch [Dawid 2006], [Bonabeau 2002] und [Garcia 2005]). Diese Aspekte sind insbesondere bei Systemen vorzufinden, die durch soziale Individuen geprägt sind (vgl. [Banks 2002]).

Die *Heterogenität* der Akteure im System kann hierbei z. B. durch eine unterschiedliche Ausstattung mit Ressourcen bzw. Informationen charakterisiert sein oder dadurch, dass ein vom Durchschnitt abweichendes Verhalten vorteilhaft ist (vgl. [Axelrod und Cohen 1999], Kap. 2). Die individuelle Umgebung eines Akteurs, welche speziell für die im Folgenden diskutierten Netzwerkeffekte relevant ist, stellt ebenfalls eine Ausprägung von Heterogenität dar. Durch Aggregation und Durchschnittsbildung bei der Betrachtung mehrerer Akteure im Rahmen der klassischen makroskopischen Modellierung, wie sie etwa bei der bereits beschriebenen kontinuierlichen Simulation zumeist erfolgt, könnten diese Unterschiede nicht ausreichend berücksichtigt werden.

Netzwerkeffekte entstehen durch gegenseitig bedingtes Entscheidungsverhalten der Akteure (vgl. Kap. 2.1.4 bezogen auf den Mobilfunkmarkt). Diese beziehen also nicht nur die eigene Situation in ihre Entscheidungen mit ein, sondern auch die aus vorangegangenen Entscheidungen entstandene aktuelle Situation von anderen Akteuren in ihrer räumlichen oder

sozialen Umgebung. Durch die Heterogenität der Akteure entstehen so z. B. individuelle Schwellenwerte bei der Bewertung von Alternativen, welche die Entscheidungen der Akteure in die eine oder andere Richtung kippen lassen können, ohne dass diese Effekte in einer weniger detaillierten Betrachtung ableitbar wären.

Das Phänomen der *Emergenz* schließlich ist in vielen komplexen Systemen vorzufinden, wo unscheinbare Einzelaktionen von Akteuren ein chaotisches Systemverhalten hervorrufen. Die Emergenz kann ein direktes Resultat der Wirkung von Netzwerkeffekten sein oder auch andere hochgradig nichtlineare Zusammenhänge im System widerspiegeln. Bei der Betrachtung längerer Zeiträume schaukeln sich diese Effekte häufig zu unerwarteten Ergebnissen auf. Für eine weiterführende und grundlegende Definition der Emergenz sei der Leser an [Peterson 2006] verwiesen, der zwar aus dem Blickwinkel der Philosophie die Charakteristika der Emergenz erschließt, diese jedoch auch für den Geltungsbereich der vorliegenden Arbeit sehr treffend analysiert.

Besonders die detaillierte (mikroskopische) Modellierung von Zustandsübergängen der Simulation durch eigenständig agierende Agenten und die daraus resultierende Flexibilität gegenüber makroskopischen Ansätzen stellen den größten Vorteil im Vergleich zu herkömmlichen Simulationsansätzen dar (vgl. [Gilbert 2007]). Umgekehrt ist es aber auch eine Voraussetzung für die Modellierung von Agenten, dass ein hinreichendes Verständnis der Mechanismen innerhalb des individuellen Verhaltens existiert, um diese modelltechnisch abbilden zu können (vgl. [Robertson 2005]).

So eröffnet die Simulation eines agentenbasierten Modells eine Vielzahl von Anwendungsmöglichkeiten: die *Diagnose* gegebenen Systemverhaltens, die *Prognose* zukünftigen Systemverhaltens, die *Szenarioanalyse*, die *Kalibrierung* von Parametern (Bottom-up-Analyse) um ein gegebenes Systemverhalten nachzuvollziehen und schließlich die *Optimierung* von Parametern (vgl. [Stahmer 2006], Kap. 3.1). Die vorliegende Arbeit beschäftigt sich insbesondere mit der Szenarioanalyse (siehe Kap. 4) und der Optimierung von Parametern der Simulation (siehe Kap. 6 f.).

3.2. Beispiele betriebswirtschaftlicher Anwendungen

Wie eingangs des Kapitels beschrieben, stellt die ABS zwar noch keine eigenständige wissenschaftliche Domäne dar, trotzdem haben schon viele Akademiker und Praktiker dieses Werkzeug zur Lösung betriebswirtschaftlicher Problemstellungen in unterschiedlichen Anwendungsgebieten verwendet. Im Folgenden werden in Kapitel 3.2.1 eine Systematik zur Klassifikation solcher Arbeiten entwickelt und in Kapitel 3.2.2 repräsentative Fallbeispiele mit konkretem Praxisbezug aus verschiedenen Wirtschaftszweigen vorgestellt. In Kapitel 3.2.3 werden dann die aus Sicht des Autors im wirtschaftlichen Kontext besonders geeigneten und gelungenen Anwendungen herausgestellt.

3.2.1. Systematik der Klassifikation

Zur Klassifikation sei eine Systematik entwickelt, die den Überlegungen in [Klein und Scholl 2004] (Kap. 2.1.2) folgend nach den beiden Dimensionen Modelltyp und Modellzweck eine Einordnung von Beispielen aus der betriebswirtschaftlichen Praxis ermöglicht.

Im *Modelltyp* wird zwischen abstrahierenden und realitätsnahen Modellen unterschieden, eine Systematik, die sich an [Parker et al. 2003] anlehnt. Viele der gezeigten Anwendungsfälle lassen sich durch diese Unterscheidung gut trennen, je nach konkreter Sichtweise ist die Zuordnung in Einzelfällen aber sicherlich nicht eindeutig. Ein *abstrahierendes Modell* ist eine theoretische Versuchsumgebung, in der Hypothesen generiert und validiert werden können. Häufig spricht man in diesem Kontext auch von einem Erklärungsmodell, da mit dieser Methodik versucht wird, speziell die bidirektionalen Wirkungszusammenhänge zwischen der Mikro- und der Makroebene zu erklären. Der Bezug zur Realität ist hierbei in der Regel nicht vollständig herstellbar, da einzelne Aspekte unterschiedlich gewichtet werden, d. h., manche Zusammenhänge werden betont, während andere vernachlässigt werden. Der Fokus liegt also auf einer normativen Analyse von Kernfragestellungen unter der Vereinfachung nicht relevanter Teilaspekte des realen Gesamtsystems. *Realitätsnahe Modelle* hingegen haben eine möglichst genaue Emulation oder Imitation des empirischen Systems zum Ziel. Sie ermöglichen durch die Abbildung realer Szenarien das retrograde Nachvollziehen von Systemeffekten sowie die Vorhersage zukünftigen Systemverhaltens. Solche Modelle werden häufig erstellt, um alternative Szenarien bzw. Konfigurationen des realen Systems analysieren zu können. Durch den Einsatz realer Parameterwerte lassen sich die verwendeten Modelle geeignet kalibrieren (siehe z. B. [Shi und Brooks 2007]).

Der *Modellzweck* bezeichnet in der Klassifikation der vorliegenden Arbeit den Forschungsgegenstand bzw. den konkreten Aspekt der Anwendung einer Modellierung. Beispiele für Praxisanwendungen finden sich in den Dimensionen *Organisationsanalyse/-design*, *Marktanalyse/-design* und *operativer Entscheidungsunterstützung* (sog. Decision-Support-Systeme). Modelle in der Dimension Organisation stellen nichtmonetäre Zusammenhänge in der Analyse und dem Design von Organisationen und deren internen Abläufen dar. Demgegenüber stellen Marktmodelle vergleichbare Bezüge in monetär orientierten Systemen her. Decision-Support-Systeme schließlich adressieren die Unterstützung operativer Entscheidungen, z. B. aus den Bereichen der Lieferketten-, Routen- oder Ablaufplanung.

3.2.2. Praxisbeispiele betriebswirtschaftlicher Anwendungen

In der betriebswirtschaftlichen Praxis findet man vielfältige Einsatzmöglichkeiten der ABS. Im Folgenden wird eine Übersicht charakteristischer Beispiele verschiedener Wirtschaftszweige vorgestellt, wobei die Motivation bei der Darstellung auf die gesamte Bandbreite der möglichen Anwendungen abzielt und weniger auf eine erschöpfende Analyse von Einzelaspekten der jeweiligen Branche. Allen gezeigten Anwendungen ist gemein, dass ihr Ausgangssystem von einer Heterogenität der Akteure, von Netzwerkeffekten sowie von Emergenz geprägt ist. Diese Aspekte treten jedoch in unterschiedlich starken Ausprägungen hervor.

Bei den referenzierten Fallbeispielen handelt es sich sowohl um praxisnahe akademische Anwendungsfälle als auch um Simulationsstudien direkt aus der industriellen Praxis. Letztere werden in der Regel in Zusammenarbeit mit spezialisierten Beratungsunternehmen oder mit akademischen Institutionen durchgeführt. Ein solches Projekt kann dabei laut [Buchanan 2005] leicht sechsstellige Summen kosten. Kriterien für die Auswahl der vorgestellten Arbeiten sind zum einen ein konkreter und praktikabler Anwendungsbezug, zum anderen der Nutzen des gezeigten Ansatzes, insbesondere auch im Vergleich zu klassischen simulationsbasierten Ansätzen. Arbeiten, die sich ausschließlich mit einer agentenbasierten algorithmischen Problemlösung ohne Simulation befassen, werden bewusst nicht berücksichtigt.

	Abstrahierende Modelle	Realitätsnahe Modelle
Organisation	(PL) [Kim 2009] (H) [Siebers et al. 2010] (F) [Robertson 2003] (F) [Markose et al. 2006] (SÜ) [Garcia 2005] (SÜ) [Barnes et al. 2010]	(PL) [Knaak et al. 2006] (H) [Venables und Bilge 1998] (H) [Hesse und Rauh 2003] (F) [Bonabeau 2002]
Markt	(E) [Bower et al. 2001] (E) [North et al. 2002] (E) [Entriken und Wan 2005] (E) [Bunn und Oliveira 2007] (E) [Müller et al. 2007] (E) [Sun und Tesfatsion 2007] (E) [Bremer et al. 2008] (PL) [Buxton et al. 2006] (PL) [Schwoon 2006] (H) [Kephart et al. 2000] (H) [Baydar 2003] (H) [Haddawy et al. 2004] (H) [Strube et al. 2007] (F) [Takahashi und Okada 2003] (F) [Arciero et al. 2009] (T) [Gerolamo et al. 2004] (T) [Frels et al. 2005]	(E) [Bunn und Oliveira 2003] (E) [Jackson 2007] (E) [Sensfuß 2008] (E) [Sensfuß et al. 2008] (E) [Weidlich 2008] (E) [Weidlich und Veit 2008b] (H) [Heppenstall et al. 2006] (H) [Kiesling et al. 2009] (H) [North et al. 2010] (F) [Darley und Outkin 2007] (F) [Outkin et al. 2008] (T) [Schade et al. 2009]
Operative Entscheidungsunterstützung	(E) [da Silva Lima und de Andrade Freitas 2006] (PL) [Swaminathan et al. 1998] (PL) [Julka et al. 2002] (PL) [Brannon et al. 2003] (PL) [Mele et al. 2007] (PL) [Davidsson et al. 2008] (H) [Midgley et al. 1997] (H) [Delre et al. 2007] (H) [Khoujaa et al. 2008] (F) [Rigopoulos et al. 2006] (SÜ) [Mizuno und Nishiyama 2003] (SÜ) [Pichitlamken et al. 2003] (SÜ) [Rindsfuser und Klügl 2007]	(E) [Praca et al. 2005] (E) [Roop et al. 2005] (E) [Sueyoshia und Tadiparthi 2008] (PL) [Gambardella et al. 1998] (PL) [Seibel und Thomas 1999] (PL) [Seibel und Kellam 2003] (PL) [Darley et al. 2004] (PL) [Vrba und Marik 2005] (PL) [Shresta und Mayer 2008] (PL) [Stranjak et al. 2008] (H) [Mizuta und Steiglitz 2000] (H) [Stahmer 2006] (H) [Lonsdale und Parker 2007]

Tabelle 1: Betriebswirtschaftliche Anwendungen der ABS

Quelle: eigene Darstellung

Tabelle 1 bietet einen Überblick der einbezogenen Arbeiten und ordnet diese entlang der vorgestellten Klassifikation. Zwischen folgenden Wirtschaftszweigen wird unterschieden: Energie (E), Produktion und Logistik (PL), Handel (H), Finanzwirtschaft (F), Telekommunikation (T) sowie sonstigen bzw. übergreifenden Ansätzen (SÜ). Nach diesen Wirt-

schaftszweigen geordnet wird in den anschließenden Abschnitten näher auf die Anwendungsfälle eingegangen.

3.2.2.1. Energie

Die Forschung zur ABS in der Energiewirtschaft ist vielfältig und stark geprägt vom Übergang zu liberalisierten Märkten, der in vielen Industrieländern stattgefunden hat. Schwerpunkte sind deshalb die Analyse von Marktstrukturen und deren Mechanismen sowie des erwarteten oder beobachteten Verhaltens der Marktakteure. Solche Systeme sind sowohl geprägt von der Heterogenität der Akteure (Stromproduzenten, -händler und -verbraucher), von Netzwerkeffekten in deren Interaktion als auch von emergenten Effekten, was die Anwendung einer ABS nahelegt. Verschiedene Autoren haben Übersichten dieser Arbeiten zusammengestellt, welche allerdings weniger die betriebswirtschaftlichen Anwendungen im Fokus haben, sondern vielmehr die Entwicklung des Forschungsfelds bzw. technische Modellierungsaspekte wie Auktionsmechanismen oder Lernverfahren (siehe [Weidlich und Veit 2008a], [Weidlich 2008], Kap. 3.3, [Sensfuß 2008], Kap. 4, oder [Marks 2006]). Viele der vorgestellten Modelle haben eine mehrjährige Entwicklungsphase mit unterschiedlichen Veröffentlichungen hinter sich, in diesem Fall besteht die Auswahl auf dem aus Sicht des Autors jeweils prominentesten Beispiel einer betriebswirtschaftlichen Anwendung.

In einer frühen Arbeit befassen sich [Bower et al. 2001] mit der Liberalisierung des deutschen Strommarktes, die anfänglich erwartungsgemäß zu einer massiven Senkung der Großhandelspreise geführt hat. Im Anschluss stiegen die Preise im Zuge einer Konsolidierungswelle unter den Versorgern aber wieder deutlich. Die Autoren stellen ein Simulationsmodell vor, das diese beiden Effekte über die strategische Motivation der handelnden Akteure ursächlich erklärt und in Verbindung setzt. Mithilfe der Simulation ist es sowohl möglich, potenzielle regulatorische Auswege aus dieser Marktsituation zu testen, als auch anderen Regulierungsbehörden im Stadium der Liberalisierung Einblicke in die emergenten Wirkungszusammenhänge zu ermöglichen.

Verschiedene Arbeiten befassen sich mit der Wirksamkeit von Regulationsmechanismen bezogen auf den liberalisierten Stromgroßhandel. Anhand des Modells EMCAS testen [North et al. 2002] aggressive heterogene Strategien der Akteure, um den gewählten Marktmechanismus auf mögliche Regelungslücken hin zu untersuchen. Außerdem wird die Robustheit des Marktverhaltens bei disruptiven Ereignissen wie Kraftwerksausfällen oder exogenen Preiseinflüssen analysiert. [Sun und Tesfatsion 2007] suchen ebenfalls mögliche Seiteneffekte der Regulierung, [Entrißen und Wan 2005] stellen darüber hinaus Zusammenhänge zu den Investitionsentscheidungen der Versorger her. [Bunn und Oliveira 2003] beurteilen schließlich, ob Marktteilnehmer unter einem neuen Marktregularium unilateral die Marktpreise durch strategische Verknappung des Angebots zu ihrem Vorteil beeinflussen können.

[Praca et al. 2005] befassen sich im Simulationsmodell MASCEM mit den vielfältigen strategischen und taktischen Aktionsmöglichkeiten im Rahmen von Strombörsen und bilateralen Abkommen, welche den Marktteilnehmern auf deregulierten Energiemärkten zur Verfügung stehen. Verschiedene in der Praxis vorgefundene Marktmechanismen lassen sich im Modell explizit berücksichtigen und erlauben so eine realitätsnahe Simulation. Diese

dient den Marktakteuren als szenariobasierte Entscheidungsunterstützung zur Bestimmung vorteilhafter Strategien.

Aus der Menge der vorgestellten Marktmodelle stechen zwei Arbeiten dadurch hervor, dass sie nicht den Strom-Großhandel (B2B), sondern den heterogenen Endkundenmarkt (B2C) modellieren. [Roop et al. 2005] simulieren dort die Auswirkungen von Preisinformationen in Echtzeit. Kunden können ihre Nachfrage dann entsprechend ihrer individuellen Preiselastizität anpassen. So verfügt der Produzent über ein effektives Instrument zur Nachfragesteuerung. Die Simulation ermöglicht den beteiligten Unternehmen ein besseres Verständnis der Auswirkungen ihrer Preisanpassungen auf die kurz- und mittelfristige Nachfragestruktur. [Bremer et al. 2008] wiederum ermitteln mit ihrem Modell, wie groß das prinzipielle Potenzial für Lastverschiebungen aufgrund dynamischer Preisstrukturen in verschiedenen Nachfrageszenarien ist. Hierbei wird angenommen, dass der Momentanverbrauch einzelner Endgeräte innerhalb eines Zeitrahmens steuerbar ist und die Kunden den Verbrauch preissensitiv optimieren.

Der brasilianische Strommarkt ist charakterisiert durch einen hohen Anteil von Wasserkraftwerken an der Grundlastversorgung. Die Autoren [da Silva Lima und de Andrade Freitas 2006] berücksichtigen in ihrem Modell des Großhandelsmarktes deshalb explizit, dass die Leistung dieses Kraftwerkstyps von der veränderlichen Wasserversorgung abhängig ist. Sie untersuchen hierbei insbesondere verschiedene operative Steuerungspolitiken, um herauszufinden, in welchen Situationen Wärmekraftwerke zur Deckung des Strombedarfs zugeschaltet werden sollen.

Der Beitrag von [Bunn und Oliveira 2007] befasst sich mit den Auswirkungen strategischer Entscheidungen von Stromproduzenten hinsichtlich ihres Portfolios an Kraftwerkstypen zur Abdeckung von Grund- und Spitzenlastanforderungen. Untersucht wird, welche Attraktionspunkte der Wettbewerbspositionierung im Strommarkt existieren und welche Auswirkungen die Diversifikation oder Spezialisierung der Marktteilnehmer in bestimmten Kraftwerkstypen auf ihre Profite und die allgemeinen Strompreise haben.

[Jackson 2007] untersucht die Wirtschaftlichkeit und den davon abgeleiteten Markterfolg dezentraler Energieerzeugung mit Blockheizkraftwerken im kommerziellen Wirtschaftssektor auf Long Island. Zentraler Analysegegenstand ist die Vergütung, die Unternehmen mit eigener Energieerzeugung bei einem Ausfall derselben an den lokalen Versorger zahlen müssen. Diese ist zum Zeitpunkt der Analyse so hoch, dass die Entscheidung für eine eigene Energieerzeugung aus wirtschaftlichen Gesichtspunkten nur für wenige Unternehmen attraktiv erscheint. Erst ab einer gewissen Marktdurchdringung der dezentralen Energieerzeugung kann der Versorger die Ausfallrisiken der einzelnen Kunden poolen und damit effektiv weniger Standby-Kapazität bereithalten, was niedrigere Vergütungen ermöglicht. Der Autor demonstriert, dass sich dieses Dilemma nur durch eine langfristig orientierte Preisung der Standby-Versorgung auflösen lässt.

In [Weidlich und Veit 2008b] und [Weidlich 2008] (Kap. 5) entwickeln die Autoren die ABS-Plattform PowerACE als Abbild eines klassischen deregulierten Energiemarktes. In den Fallstudien [Sensfuß 2008] (Kap. 6) und [Sensfuß et al. 2008] werden damit die Auswirkungen der Einspeisung erneuerbarer Energien auf die Strompreise, auf Investitionsentscheidungen der Kraftwerksbetreiber sowie auf die CO₂-Emissionen des Kraftwerksportfolios analysiert.

Das Ergebnis zeigt unter anderem, dass die vom Verbraucher zu tragenden Kosten erneuerbarer Energien deutlich geringer sein können als durch die Höhe der Einspeisungsvergütung suggeriert (aufgrund des sog. Merit-Order-Effekts) und dass betriebswirtschaftliche Erwägungen der Kraftwerksbetreiber vor allem zu einer Substitution von Steinkohlekraftwerken durch die erneuerbaren Energiequellen führen werden. In einer weiteren Fallstudie analysieren [Müller et al. 2007] mithilfe einer Version dieses Modells die beobachteten steigenden Preise im deutschen Endkunden-Strommarkt. Sie zeigen anhand der Simulation, dass diese Effekte allein ein Resultat der nur schwach ausgeübten Marktmacht der Kunden sein können, ohne dass steigende Produktionskosten oder Preisabsprachen unter den Stromerzeugern vorliegen.

Entscheidungen über die Höhe von Geboten auf Großhandels-Strombörsen haben eine signifikante finanzielle Auswirkung für die bietende Partei. Gleichwohl müssen die Entscheidungen unter großer Unsicherheit innerhalb sehr kurzer Zeitspannen erfolgen. Zur Unterstützung solcher Preisentscheidungen stellen [Sueyoshia und Tadiparthi 2008] eine ABS vor, welche die dynamische Preisbildung in verschiedenen Szenarien nachzeichnet und so die zu erwartenden Preise prognostiziert. Auf Testdaten des kalifornischen Strommarktes zeigen die Autoren die überlegene Prognosegüte ihres Modells im Vergleich zu alternativen Ansätzen.

3.2.2.2. Produktion und Logistik

Innerhalb der eng miteinander verwobenen Wirtschaftszweige Produktion und Logistik ergeben sich ebenfalls vielseitige Anwendungen der ABS, welche vor allem durch die Adressierung von Netzwerkeffekten geprägt sind. Diesen Bereichen ist insbesondere gemein, dass an den Geschäftsprozessen häufig eine große Anzahl unterschiedlicher Geschäftspartner beteiligt ist, z. B. bei Lieferketten über Abteilungs- und Unternehmensgrenzen hinweg.

Zur Beurteilung der Robustheit operativer Richtlinien gegenüber stochastischen Einflüssen wie den Transport- und Umladezeiten im Betrieb eines Containerterminals haben [Gambardella et al. 1998] ein Simulationsmodell entwickelt, das den Ablauf in einem solchen Terminal nachbildet. Die von den Autoren vorgestellten Fallstudien belegen, dass das Modell zur Unterstützung bei der Bewertung und Anpassung verschiedener Ressourcenallokationen dienlich ist.

[Swaminathan et al. 1998] beschreiben in ihrer Arbeit eine ABS, die Manager bei der Umstrukturierung ihrer Lieferketten unterstützt. Die Simulation ermöglicht eine quantitative Beurteilung der Erfolgsfaktoren (wie Profite oder Durchlaufzeiten) und Risiken verschiedener Konfigurationen und Steuerungsmechanismen der Lieferkette. Als Anwendung des Modells wird eine Implementierung in der Lagerverwaltung bei IBM vorgestellt, in der optimale Zielgrößen für Lagerbestände ermittelt und deren Auswirkungen von den betroffenen Managern analysiert werden können.

Zur Optimierung der Frachtabfertigung bei Southwest Airlines zeigen [Seibel und Thomas 1999] ein agentenbasiertes Simulationsmodell, mit dem typische Szenarien in der vernetzten Abwicklung auf ihre Effizienz hin untersucht werden können. Als Ergebnis der Studie wurde ein Handbuch für die Frachtabfertiger erstellt, das bei der Wahl einer optimalen

Route für das Transportgut unterstützt und die bis dahin verwendeten individuellen Faustregeln ersetzt. Dies hat zu drastisch gesenkten Kosten für untertägige Lagerung sowie zu niedrigerem Aufwand für die Abfertigung an Zwischenstationen auf der Transportroute geführt.

In [Julka et al. 2002] präsentieren die Autoren das System PRISMS, welches die Lieferkette innerhalb eines Petrochemie-Clusters mithilfe von Agenten simuliert. Eine Fallstudie befasst sich eingehender mit verschiedenen Fragestellungen der taktischen und operativen Planung auf der Ebene einer einzelnen Ölraffinerie: den Auswirkungen von Entscheidungen zur Einkaufslosgröße, der Robustheit der Produktion gegenüber Nachfrageschwankungen sowie den Auswirkungen zusätzlicher Lagerkapazität.

Zur Optimierung der Logistik des Konsumgüterherstellers Procter & Gamble stellen [Seibel und Kellam 2003] in ihrer Fallstudie ein Modell vor, das die gesamte Lieferkette von der Produktion bis zum Handel abdeckt. Ziel der Simulation ist ein besseres Verständnis, wie das in Warenbeständen gebundene Umlaufkapital und die Wahrscheinlichkeit von ausverkauften Waren reduziert werden können. Auf Basis der so gewonnenen Erkenntnisse wurden verschiedene operative Umstellungen umgesetzt, z. B. ermöglicht die Durchführung von Transporten auch bei nicht vollständig gefüllten Lastwagen nun eine deutliche Reduzierung der Volatilität im Gesamtsystem und somit der Häufigkeit ausverkaufter Waren im Handel.

Die Textilindustrie unterliegt einem Wandel weg von einer „Push“- hin zu einer „Pull“-Strategie, bei der die Produkte direkt auf die Bedürfnisse einzelner Kundengruppen zugeschnitten werden. In diesem Kontext dient das „Virtual Customer“-Simulationsmodell aus [Brannon et al. 2003] der Analyse des Konsumentenverhaltens mit dem Ziel einer maßgeschneiderten Produktentwicklung. Die simulierten heterogenen Kunden werden durch demografische Daten und individuelle Motivationen charakterisiert und zeigen ein komplexes Entscheidungsverhalten unter Einbeziehung subjektiver und rationaler Kriterien. So werden sowohl existierende Kundengruppen als auch neue Zielsegmente abgebildet.

In [Darley et al. 2004] wird die Implementierung einer ABS des Produktionsprozesses bei der Firma SCA Packaging beschrieben, einem Hersteller von Kartonverpackungen. Ziel ist die Optimierung der Lagerhaltung von Endprodukten mithilfe von Szenarioanalysen. Als Resultat wird ein verbessertes Verständnis der Kostentreiber im gesamten Produktionsprozess beschrieben. Durch eine Anpassung der Kundenstruktur sowie durch Veränderungen im Produktionsprozess konnten die Lagerbestände des Unternehmens um über 35 % gesenkt werden.

[Vrba und Marik 2005] stellen die Anwendung ihrer agentenbasierten Simulationsumgebung MAST vor, die Materialflüsse in einer vernetzten Produktionsstraße abbildet. Mit dieser Simulation können verschiedene Ansätze zur Produktionssteuerung unter realitätsnahen Bedingungen auf ihre Robustheit und auf ggf. auftretende Anomalien getestet werden, ohne kostspielige und potenziell gefährliche Versuche am realen System durchführen zu müssen. Die Wertschöpfungskette eines Flugzeugtriebwerks erstreckt sich von der Entwicklung und Produktion, dem Verkauf auf dem Primärmarkt bis hin zu nachgelagerten Wartungsdienstleistungen. [Buxton et al. 2006] simulieren entlang dieser Kette die Interaktionen der beteiligten Unternehmen, um auf strategischer Ebene die Auswirkungen externer Einflüsse wie

z. B. disruptiver Nachfrageschwankungen im Flugverkehr auf die einzelnen Geschäftsmodelle transparent zu machen. [Stranjak et al. 2008] beschäftigen sich hingegen speziell mit der Planung der Wartungszyklen. Die Autoren bilden das komplexe Zusammenspiel der Faktoren Auslastung, Kosten und Risiko in einer ABS ab, welche zur Szenarioanalyse im Falle außerplanmäßiger Wartungsbedarfe herangezogen wird. Verschiedene mögliche Wartungspläne lassen sich so auf ihre Effizienz und Robustheit hin überprüfen. Außerdem dient die Simulation der Bewertung strategischer Kapazitätsentscheidungen über die Anzahl von Werkstätten und die Lagermengen von Austauschteilen.

Für einen lokalen Kurierdienst in Hamburg untersuchen [Knaak et al. 2006] verschiedene Logistikkonzepte. Neben der operativ gelebten Praxis, die eingehenden Aufträge einzeln an freie Kurier auszusprechen, wird die Effizienz fortgeschrittener Konzepte mit Übergaben an festen Verteilpunkten bzw. mit einer Zerlegung von Bündelaufträgen analysiert. Mithilfe der Daten zu 2.100 realen Aufträgen werden die individuell optimalen Entscheidungen der Kurier zur Erfüllung dieser Liefertouren simuliert und für verschiedene Konzepte die jeweils gesamthaft zurückgelegte Wegstrecke ermittelt. Insbesondere die Problematik potenziell leerer Pendeltouren zwischen Verteilpunkten stellt sich hierbei als ein Hindernis für Änderungen am Status quo heraus.

In [Schwoon 2006] beschreibt der Autor detailliert sein Modell eines Marktes für Brennstoffzellen-Fahrzeuge. Ziel der Untersuchung ist die Frage, mit welchen fiskalischen Maßnahmen eine Markteinführung solcher Fahrzeuge flankiert werden sollte und welche Auswirkungen diese auf die Hersteller und den Ausbau der Tankstelleninfrastruktur haben. Die Kunden entscheiden aus wirtschaftlichen Gesichtspunkten, aber auch konform zu ihrem sozialen Umfeld. Wenig überraschend hilft eine steuerliche Verteuerung konventioneller Fahrzeuge, die Attraktivität der alternativen Antriebstechnologie zu steigern und so die Markterschließung zu erleichtern.

[Mele et al. 2007] bewerten die Profitabilität verschiedener strategischer Konfigurationen einer Lieferkette mittels einer ABS. Lagerhaltungsparameter werden dabei mit einem genetischen Algorithmus innerhalb stochastischer Problemausprägungen mit unterschiedlichen Aufträgen, Lieferzeiten etc. optimiert.

Das in [Davidsson et al. 2008] beschriebene Modell TAPAS ermöglicht die Simulation des Transports von Gütern unter Berücksichtigung der verschiedenen Transportmodi Straße, Schiene und Schiff. In einer Fallstudie analysieren die Autoren damit die Auswirkungen der Einführung einer Lkw-Maut in Schweden auf die miteinander vernetzten Entscheidungen der beteiligten Produzenten, Transporteure und Kunden. Es zeigen sich Effekte auf die Häufigkeit der Lieferungen, den gewählten Modus und die daraus resultierende Umweltbilanz der Transporte.

[Shresta und Mayer 2008] simulieren die operativen Abläufe der Flugsicherung am Flughafen von Atlanta. Das Modell bildet sowohl die stochastischen Ankunftszeiten der Flugzeuge als auch die Prozesse der Flugsicherung realitätsnah ab und erhebt zentrale Bewertungsgrößen wie die Zwischenlandezeiten der Flugzeuge und die Länge der ggf. vor der Landung zu fliegenden Warteschleifen. In einer vorgestellten Anwendung werden mit der anhand empirischer Daten validierten Simulation die Auswirkungen von Änderungen der

operativen Prozesse untersucht, insbesondere auch bei einem Stresstest unter hoher Auslastung.

Das „Beer game“ ist eine häufig exemplarisch verwendete betriebswirtschaftliche Simulation von Informations- und Warenflüssen in einer Lieferkette. Anstatt üblicher Ansätze, welche hierbei die Bedeutung eines reibungslosen Informationsaustausches betonen, analysiert [Kim 2009] mit einer ABS die Auswirkungen von Vertrauen (hinsichtlich der zuverlässigen Lieferung bestellter Waren) zwischen den Akteuren einer solchen Lieferkette. Der Autor kann mit der Simulation nachvollziehen, wie gegenseitiges Vertrauen zu stabilen langfristigen Kollaborationen der beteiligten Parteien führt, und wie hierdurch eine Reduktion der Variabilität der Bestellmengen und eine Stabilisierung der Lagerbestandsmengen erzielt werden.

3.2.2.3. Handel

Der Handel, speziell im Endkundenbereich, ist eine prädestinierte Domäne für die ABS, da Kunden in der Regel ein heterogenes Präferenzverhalten aufweisen. Außerdem existieren verschiedenste Interaktionsmöglichkeiten, z. B. im Rahmen des Verkaufsprozesses, bei Produktempfehlungen oder bei Kundenwerbungen. Schließlich bieten die in diesem Wirtschaftszweig vielfach eingesetzten CRM-Systeme²⁰ eine detaillierte Datenbasis für die Analyse des Entscheidungsverhaltens der Akteure, was eine realitätsnahe Kalibrierung der Agenten in der Simulation ermöglicht. Entsprechend finden sich in diesem Segment sogar Anbieter von Standardsoftware wie z. B. ShopSim²¹, mit dem das Verhalten individueller Kunden bei der Einkaufstour durch ein Geschäft oder ein Einkaufszentrum simuliert werden kann.

[Midgley et al. 1997] simulieren in einem einfachen Modell die Marketingentscheidungen von Produktmanagern im kompetitiven Einzelhandel von Kaffee. Die möglichen Strategien werden mit einem genetischen Algorithmus optimiert und mit empirisch beobachteten Strategien verglichen. Neben dem naheliegenden Anwendungszweck, Manager in ihrer Entscheidungsfindung zu unterstützen, diskutieren die Autoren eine interessante Möglichkeit: Da die simulierten Agenten einen postulierten maximalen Wettbewerbsgrad auf dem Markt herstellen, könnte ein solches Modell Regulierungsbehörden als Referenzindikator für den Wettbewerb auf dem Markt dienen.

Das in [Venables und Bilge 1998] vorgestellte Modell SimStore ist Grundlage eines Anwendungsprojektes bei der Handelskette J Sainsbury. Analysiert werden Fragestellungen z. B. hinsichtlich der Platzierung von Waren, der Optimierung von Einkaufstouren oder der Festsetzung von Öffnungszeiten. Hauptgegenstand der Simulation sind dabei Aspekte der Kapazitätsauslastung, sowohl bezogen auf den gesamten Supermarkt (gleichmäßige Verteilung der Kunden über die Öffnungszeit) als auch auf einzelne räumliche Bereiche (Ver-

²⁰ Customer-Relationship-Management (CRM)-Systeme erheben eine Vielzahl transaktionaler Daten entlang des gesamten Kundenkontakts und Verkaufsprozesses.

²¹ <http://www.savannah-simulations.com/shopsim/>, abgerufen am 28. Februar 2009.

meidung gegenseitiger Behinderung). Mit operativen Daten aus der Warenkorbanalyse wird das Modell an die Situation im realen Supermarkt angepasst.

Auf Märkten, die von digitalen Informationen dominiert werden, erwarten [Kephart et al. 2000] einen entscheidenden Einfluss sogenannter Pricing- und Shopping-Bots. Gegenstand ihrer Analyse ist deshalb, welche Strategien in einem solchen Umfeld für Verkäufer sinnvoll sind und insbesondere die Frage, welche Möglichkeiten und Auswirkungen dynamisches Pricing mit sich bringt. In der Simulation werden Agenten mit verschiedenen Pricing-Strategien verglichen und bewertet. Außerdem untersuchen die Autoren, welche Rolle eine Produktdifferenzierung bzw. eine Produktbündelung in diesem Kontext spielen kann.

Onlineauktionen haben einen wachsenden Stellenwert im B2C- und C2C-Handel erlangt. [Mizuta und Steiglitz 2000] simulieren einen typischen Auktionsprozess, an dem zwei in empirischen Untersuchungen als zentral identifizierte Typen von Akteuren beteiligt sind: Bieter, die zu Beginn ein finales Gebot abgeben, und sogenannte Sniper, die erst zum letztmöglichen Zeitpunkt bieten. Die Autoren zeigen, dass die frühen Bieter zwar im Durchschnitt niedrigere Preise zahlen, aber seltener den Zuschlag bekommen. Die Sniper-Strategie stellt sich somit als grundsätzlich effektiv und für den Anwender als erfolgversprechend heraus.

Für Preisrabatte im Einzelhandel zeigt [Baydar 2003] ein Simulationsmodell, das kunden-spezifische Rabatte mit der Rabattgestaltung im Rahmen eines Kundenkartenprogramms vergleicht. In einer Fallstudie demonstriert er, dass individuelle Preisnachlässe zu einer gesteigerten Kundenzufriedenheit bei gleichem Werbebudget führen können, oder umgekehrt eine konstante Zufriedenheit mit einem Drittel des Budgets erreicht werden kann.

[Hesse und Rauh 2003] bilden ein reales Einkaufszentrum in einem Simulationsmodell ab und untersuchen dort die räumliche Angebotsgestaltung. Ausgangspunkt hierbei ist die Annahme, dass das Einkaufsverhalten der Kunden durch die räumliche Platzierung und Abfolge der Geschäfte beeinflusst werden kann. Die Modellierung des heterogenen Kundenverhaltens erfolgt anhand empirischer Daten aus einem Einkaufszentrum in Ansbach und dient der realistischen Simulation der Kundenströme. In der Simulationsumgebung kann eine räumliche Um- oder Neugestaltung des Einkaufszentrums vorgenommen und eine (nach zu definierenden Kriterien wie z. B. der Aufenthaltsdauer oder den zurückgelegten Wegen) optimale Geschäftsanordnung hergeleitet werden. Dabei wird ein visueller wie auch quantitativer Vergleich mit dem Status quo möglich.

Den Auktionsverlauf auf einer B2B-Handelsplattform simulieren die Autoren in [Haddawy et al. 2004]. Anhand realer Transaktionsdaten lernen die Agenten das Verhalten der am Handel beteiligten Unternehmen. Da der kommerzielle Erfolg der Handelsplattform proportional zum Wert der gehandelten Güter steigt, beleuchtet die Simulationsstudie insbesondere den Einfluss verschiedener Broker-Strategien auf das Handelsvolumen.

Die Variabilität von Benzinpreisen ist ein Phänomen, das neben den schwankenden Großhandelspreisen vor allem vom lokalen Konkurrenzkampf der Tankstellen abhängt.

[Heppenstall et al. 2006] betrachten deshalb die Auswirkungen kurzfristiger Preis- wie auch langfristiger Standortentscheidungen im Kraftstoffmarkt der Region West Yorkshire anhand realer Benzinpreisdaten. Das gezeigte Modell kann sowohl lokale Preisdifferenzen als auch

dynamische Anpassungsprozesse als Reaktion auf exogene Preiseinflüsse realistisch simulieren.

In Kapitel 5 seiner Dissertation befasst sich [Stahmer 2006] mit einer Simulation des Abverkaufsprozesses von Produkten im Einzelhandel. Mithilfe einer umfangreichen Kalibrierung anhand von Verkaufsdaten verschiedener Supermärkte baut er ein realitätsnahes Verhaltensmodell der Kunden auf und berücksichtigt auch komplexe Abhängigkeiten zwischen Produktverkäufen. Dieses Simulationssystem ermöglicht eine Analyse der Auswirkungen von Maßnahmen des Sortimentsmanagements (wie z. B. Preis-, Sortiments- oder Platzierungsänderungen) und des Produktmarketings.

Bei der Markteinführung neuer Produkte spielen Netzwerkeffekte (wie Mundpropaganda) eine entscheidende Rolle. [Delre et al. 2007] nutzen ein agentenbasiertes Modell, um den Diffusionsprozess neuer Produkte zu simulieren. So gewinnen sie Erkenntnisse darüber, welche Strategien zur Zielgruppenansprache geeignet sind und welche zeitliche Koordination mit Werbemaßnahmen effizient ist, um einen hohen Marktanteil zu erreichen.

[Lonsdale und Parker 2007] stellen mit dem „Universal Market Simulator“ (UMS) ein bei Boeing entwickeltes System vor, das die Umsatzgenerierung durch Flugpassagiere modelliert. Fluglinien können dieses Werkzeug im Rahmen ihres Revenue Managements nutzen, um die Auswirkungen von Preisentscheidungen auf das Kaufverhalten einer großen Anzahl individuell motivierter Agenten zu simulieren. Das System berücksichtigt sowohl ein realistisches Buchungsverhalten der Passagiere als auch verschiedene Buchungsklassen aufseiten der Fluglinien. Anwendungen werden im Rahmen der Szenarioanalyse bei der Einführung neuer Produktkonzepte sowie für die strategische Ausrichtung im Wettbewerb mit anderen Fluglinien beschrieben.

Der Markt für Videospielkonsolen ist ein klassisches Beispiel für das Auftreten indirekter Netzwerkeffekte. [Strube et al. 2007] nutzen eine ABS, um den Markterfolg einer neuen Konsole im komplexen Zusammenspiel zwischen der technischen Ausstattung, dem Angebot an kompatiblen Spielen und einsetzender Mundpropaganda zu untersuchen. Die Autoren bestätigen den Erfolg der marktüblichen Praxis, mit niedrigen Einstiegspreisen für die Konsole rasch eine signifikante Marktdurchdringung zu erlangen und dann über Lizenzgebühren für Spiele Gewinne abzuschöpfen.

In der Fallstudie [Khoujaa et al. 2008] analysieren die Autoren das Zusammenspiel einer optimalen Preis- und Rabattgestaltung auf die Profitabilität eines Produktherstellers und betrachten hierbei insbesondere den Effekt von Mail-in-Rabatten. Untersucht wird, wie Kunden solche Rabatte in Relation zu deren Kosten beurteilen, und mit welcher Wahrscheinlichkeit Mail-in-Rabatte eingelöst werden. Die agentenbasierte Modellierung erlaubt es den Autoren, individuelle Erfahrungshistorien der Kunden zu berücksichtigen, die sich als entscheidend bei der Beurteilung von Rabatten für wiederkehrende Kaufentscheidungen herausstellen.

[Kiesling et al. 2009] simulieren die Einführung von Biosprit auf dem österreichischen Kraftstoffmarkt. Das neue Benzin ist zwar zunächst den Kunden unbekannt, kann aber mit überlegenen Attributen aufwarten. Berücksichtigt werden wiederkehrende Käufe, Erfahrungen mit dem Kraftstoff und speziell der Austausch diesbezüglicher Informationen mit anderen Kunden. In einem ungewöhnlich detaillierten Ausmaß fundieren die Autoren die Agenten

und deren Entscheidungen anhand empirisch erhobener Daten aus Kundenbefragungen. Im Ergebnis zeigen sie, dass sich ein solches Produkt potenziell schnell auf dem Markt etablieren kann, selbst bei einem höheren Preis gegenüber konventionellen Kraftstoffen.

Aus einem langjährigen Praxisprojekt mit Procter & Gamble heraus beschreiben [North et al. 2010] das „Virtual market learning laboratory“ zur Simulation eines Konsumgütermarktes. Für Kunden wie auch Händler wurde bei deren Modellierung auf umfangreiche Datensätze realer Verkaufsstellen (wie demografische Daten und reales Kaufverhalten) zurückgegriffen und so ein realitätsnahes agentenbasiertes Modell erzeugt. Eingesetzt werden soll das Modell bei der Überprüfung der Robustheit von Marktstrategien sowie bei der Exploration zukünftiger Markttrends. Laut den Autoren wurden Erkenntnisse aus diesem Projekt bereits zur Patentierung angemeldet.

Das Simulationsmodell ManPraSim aus [Siebers et al. 2010] dient der Analyse vernetzter Wechselwirkungen zwischen Praktiken im Personalmanagement und der operativen Effizienz in Verkaufsabteilungen. Die Autoren untersuchen Möglichkeiten der Personaleinsatzplanung und des Kundenservice und simulieren die resultierenden Kaufentscheidungen der Kunden auf Basis empirischer Daten aus Kaufhäusern. Zentrales Steuerungsinstrument ist hierbei die Kundenzufriedenheit, welche durch Serviceerfahrungen hinsichtlich Wartezeiten, Beratung und Umtauschpolitik sowie durch Mundpropaganda beeinflusst wird.

3.2.2.4. Finanzwirtschaft

Die Bewertung operativer Risiken bei Banken ist generell schwierig, da eine Vielzahl von Risikoausprägungen möglich ist, welche aber nur äußerst selten auftreten. Historische Erfahrungen liefern also nur eine rudimentäre Datenbasis für die Einschätzung des Risikos. [Bonabeau 2002] stellt deshalb eine Analyse vor, in der das operative Risiko der Bank Société Générale mithilfe von Agenten simuliert wird. Die Simulation der Prozesse der Bank ermöglicht es, eine breitere Datenbasis für die Bewertung insbesondere emergenter Risiken zu erlangen und diese besser spezifizieren zu können. So benötigt die Bank potenziell weniger Eigenkapital zur Abdeckung des präziser quantifizierten operativen Risikos.

Die Strategieentwicklung von Unternehmen in einem dynamischen kompetitiven Markt untersucht [Robertson 2003]. Der Autor bezieht sich zwar explizit auf die Bankenbranche, zeigt aber ein generisches Modell, das ebenso auf andere Wirtschaftszweige anwendbar ist. Er simuliert die Positionierung von Unternehmen in zwei Dimensionen relevanter strategischer Einflussfaktoren. Kunden interessieren sich für Unternehmen, die im strategischen Raum möglichst nahe ihrer eigenen Positionierung entsprechen. Das Modell soll dazu dienen, wesentliche strategische Stoßrichtungen zu identifizieren, in denen sich weitere empirische Analysen lohnen.

Zur Analyse der Entstehung von Bewertungsblasen auf einem Immobilienmarkt simulieren [Takahashi und Okada 2003] die vernetzten Zusammenhänge zwischen der Kreditvergabe von Bankinstituten und dem regulatorischen Einwirken der Zentralbank. Die Studie zeigt, dass ein konservativer Ansatz der Banken bei der Kreditvergabe und ein aktives Management der Risiken gefährdeter Hypotheken wirksam vor einer Krise schützen. Nur wenn dies nicht der Fall ist, wirkt sich eine aktive Liquiditätssteuerung der Zentralbank positiv zur Stabilisierung des Marktes aus.

Mehrere Autoren betrachten den Zahlungsverkehr zwischen Banken und einer Zentralbank. [Markose et al. 2006] untersuchen hierbei Mechanismen zur Liquiditätssteuerung: Um ihre benötigte Liquiditätsreserve zu minimieren, versuchen Banken ausstehende Zahlungen im Falle temporär knapper Liquidität so lange zu verzögern, bis ein anderer Geldeingang die Zahlung ermöglicht. Verfolgen mehrere Banken eine solche Strategie, so zeigt die Simulation dynamische Rückkopplungseffekte und eine resultierende Verringerung der Effizienz im Zahlungssystem. Ein Ergebnis der Untersuchung ist außerdem, dass je nach Steuerungsmechanismus durch die Verzögerung von Zahlungen ein Rückstau nicht erfüllter Transaktionen erfolgt, der das operative Risiko der am System beteiligten Banken erhöht. [Arciero et al. 2009] hingegen betrachten die Abhängigkeiten zwischen dem Zahlungsverkehr und dem Geldmarkt im Falle des Konkurses einzelner Banken. Die Autoren zeichnen charakteristische Effekte im Markt nach und ermöglichen es der Zentralbank mit diesem Modell, in einem Stresstest mögliche Interventionsszenarien zur Stabilisierung des Marktes durchzuspielen.

Der Markterfolg elektronischer Zahlungssysteme hängt von schwer vorhersehbaren Netzwerkeffekten im Zusammenspiel der Akzeptanz bei Händlern wie bei Kunden ab. [Rigopoulos et al. 2006] adressieren dieses Problem mithilfe einer ABS der Alternativenauswahl der Endkunden, welche Zahlungsmöglichkeit sie zur Maximierung ihres individuellen Nutzens verwenden möchten. Die Händler entscheiden dann anhand des erwarteten zusätzlichen Umsatzes im Kontrast zu den Mehrkosten der Implementierung dieser weiteren Zahlungsmöglichkeit. Die Simulation dient dazu, vorab die Marktaussichten neuer Zahlungssysteme besser einschätzen zu können.

[Darley und Outkin 2007] erstellen in ihrer umfangreich dokumentierten Studie ein agentenbasiertes Simulationsmodell des amerikanischen Aktienmarktes NASDAQ. Untersucht werden die Auswirkungen struktureller Veränderungen des Marktmechanismus auf das Verhalten der Händler und auf das sich daraus dynamisch ergebende Gesamtverhalten des Marktes bezüglich Handelsvolumina, Volatilitäten und Preisen. Im Rahmen der Simulation generierte Hypothesen werden anhand empirischer Daten hinterfragt und validiert.

Das Funktionieren der Finanzmärkte hängt entscheidend von einer reibungslos operierenden Infrastruktur für Strom und Telekommunikation ab. [Outkin et al. 2008] simulieren mit ihrem Modell FinSim die Interaktionen der Finanzakteure und -institutionen bei der Abwicklung im Zahlungsverkehr sowie auf dem Aktien- und Geldmarkt. Sie untersuchen die Auswirkungen von Störungen der Infrastruktur, die zu einem temporären Ausfall beteiligter Institutionen führen. Der amerikanische Finanzmarkt wird dabei mit Realdaten zu seiner geografischen, organisatorischen und finanziellen Situation abgebildet. Diskutiert wird die Fragestellung, welche Maßnahmen die Zentralbank im Falle eines solchen Ereignisses ergreifen kann, um wirksam einen Kollaps des hochgradig vernetzten Finanzmarktes zu vermeiden.

3.2.2.5. Telekommunikation

[Gerolamo et al. 2004] simulieren die Entwicklung eines kompetitiven Telekommunikationsmarktes. Verschiedene heterogene Typen von Konsumenten, wie Innovatoren und konservative Nutzer, entscheiden über den Abschluss eines Vertrags bei

einem der Serviceprovider bzw. über einen entsprechenden Wechsel. Neben dem Preis und der Servicequalität stellt insbesondere die Marktdurchdringung des Produkts in der Nachbarschaft der Kunden ein zentrales und differenzierendes Entscheidungskriterium dar. Näher analysiert werden unter anderem die Auswirkungen verschiedener Parameter auf das Wechselverhalten der Kunden sowie die Voraussetzungen für statische bzw. dynamische Marktverhältnisse im Laufe der Simulation.

In [Frels et al. 2005] untersuchen die Autoren den Einfluss von Netzwerkeffekten auf den Erfolg aggressiver Penetrationsstrategien bei der Preisgestaltung. Am vereinfachten Beispiel der Einführung eines neuen Mobilfunkgeräts zeigen sie, dass in Märkten mit starken Netzwerkeffekten das frühzeitige Erreichen eines überlegenen Marktanteils von entscheidender Bedeutung für den mittel- bis langfristigen Markterfolg ist. Anhand von Laborexperimenten werden die Entscheidungsregeln der Agenten an das reale Entscheidungsverhalten der Kunden kalibriert.

[Schade et al. 2009] analysieren den Markteintritt eines neuen Anbieters auf dem weitgehend gesättigten deutschen Mobilfunkmarkt für Sprachtelefonie. Anhand realistischer Profile von Nutzergruppen werden insbesondere die Netzwerkeffekte durch verbilligte netzinterne Gespräche näher untersucht, die einem neuen Wettbewerber den Markteintritt erschweren. Im Ergebnis kristallisiert sich unter verschiedenen möglichen Preisstrategien ein aggressiver Discountpreis als einzig realistische Möglichkeit für die Etablierung des neuen Anbieters auf dem Markt heraus.

3.2.2.6. Sonstige/übergreifende Ansätze

Fernsehzuschauer entscheiden sich für eine Sendung nicht nur auf Basis statischer Kriterien, sondern beziehen auch die Gewohnheiten anderer Personen mit ein, indem sie sich besonders für populäre Sendungen interessieren oder auch zusammen mit anderen Personen fernsehen. [Mizuno und Nishiyama 2003] berücksichtigen dieses vernetzte Entscheidungsverhalten mit einer an realen Daten kalibrierten ABS der Einschaltquoten verschiedener Sender. Die Autoren unterstützen mit diesem Werkzeug Programmverantwortliche darin, die Konsequenzen von Veränderungen im Programmplan besser einschätzen zu können.

[Pichitlamken et al. 2003] befassen sich mit dem Betrieb eines Callcenters. Die Simulation des Systems ist komplex, da die Telefonisten bei niedriger Auslastung neben der Beantwortung eingehender Anrufe auch abgehende Anrufe tätigen müssen und während dieser Zeit nicht anderweitig zur Verfügung stehen. Die Autoren testen verschiedene operative Einflussmöglichkeiten aus der Personalplanung und dem Service-Level-Management auf die Performanceindikatoren des Callcenters.

[Garcia 2005] untersucht den Erfolg diverser Innovationsstrategien in einem kompetitiven Markt. Hierzu vergleicht die Autorin den Markterfolg neuer Produkte mit den dafür aufgewendeten Forschungs- und Entwicklungsgeldern, wobei die vorhandenen Ressourcen zwischen neuen innovativen Produkten und Weiterentwicklungen existierender Produkte aufgeteilt werden können. Die Ergebnisse legen den Schluss nahe, dass in dem modellierten Umfeld eine defensive Innovationsstrategie durchaus erfolgversprechend ist.

In [Rindsfuser und Klügl 2007] zeigen die Autoren eine ABS von Passagierströmen auf dem Berner Bahnhof. Im Auftrag der Schweizer Bahngesellschaft SBB wurde analysiert, welche

Auswirkungen die Fahrplangestaltung und die Eröffnung weiterer Durchgangswege auf den Passagierdurchsatz und entstehende Wartezeiten haben. Umgekehrt wurde außerdem untersucht, ob die existierende Infrastruktur des Bahnhofs die prognostizierten steigenden Passagierzahlen zukünftig verarbeiten kann. Als Resultat konnten potenzielle Nadelöhre in der Gestaltung des Bahnhofs identifiziert werden.

[Barnes et al. 2010] zeigen eine der raren Anwendungen einer ABS im Bereich der Gesundheitspflege. Die Autoren untersuchen die Ausbreitung multiresistenter Bakterien (sog. MRSA) in Krankenhäusern. Diese werden für eine signifikante Anzahl von Infektionen (bis hin zu Todesfällen) und damit zusammenhängenden Kosten verantwortlich gemacht. In der Simulation werden Ärzte, Krankenschwestern, Patienten und Besucher als die möglichen Überträger modelliert und die Auswirkungen verschiedener Richtlinien und Verfahrensweisen zur Herabsetzung des Infektionsrisikos analysiert. Es zeigt sich unter anderem, dass insbesondere Ärzte eine zentrale Rolle bei der Übertragung spielen, aber auch, dass selbst beim Vorliegen adäquater Vorkehrungen ein Ausbruch aufgrund exogener Faktoren nicht ausgeschlossen werden kann.

3.2.3. Beurteilung der Praxisanwendungen

Alle vorgestellten betriebswirtschaftlichen Anwendungsfälle zeichnen sich dadurch aus, dass sie die in Kapitel 3.1.3 genannten zentralen Anwendungscharakteristika der ABS – Heterogenität, Netzwerkeffekte und Emergenz – zumindest in Ansätzen adressieren und nutzen. Besonders gelungene Beispiele weisen zudem eine hohe Praxisrelevanz auf und können als State-of-the-art der anwendungsbezogenen ABS-Forschung angesehen werden. Diese Beispiele werden hier nochmals kurz aufgegriffen.

Die auf Basis der Simulationsplattform PowerACE (vgl. [Weidlich 2008]) entwickelten Fallstudien adressieren insbesondere das intelligente Verhalten der verschiedenen Akteure auf den vernetzten deutschen Energiemärkten und sorgen durch eine Validierung der Simulationsergebnisse anhand umfangreicher empirischer Daten dafür, dass sich die Simulation direkt für Aussagen über den zugrunde liegenden realen Markt eignet. Eine vergleichbar umfangreiche Modellierung, allerdings mit einer Ausrichtung auf den Finanzmarkt NASDAQ, zeigen [Darley und Outkin 2007]. Die Praxisrelevanz ihrer Analyse wird nicht zuletzt durch den kommerziellen Ursprung der Studie unterstrichen. Das Modell SimStore in [Venables und Bilge 1998] zeichnet sich weniger durch die Ausnutzung technisch fortschrittlicher Verfahren aus, sondern durch einen intuitiven und trotzdem für die Anwendung geeigneten einfachen Simulationsansatz, der vor allem das individuelle Entscheidungsverhalten der Kunden und daraus entstehende emergente Effekte berücksichtigt. Noch detailgetreuer in der Abbildung der relevanten Faktoren des realen Systems sind [Lonsdale und Parker 2007] in ihrem Modell UMS, welches sowohl individuell agierende Kunden als auch vernetzte Unternehmensprozesse direkt berücksichtigt. Insbesondere durch die Integration transaktionaler Daten aus verschiedenen operativen Systemen bestätigt es den Eindruck einer fortschrittlichen Innovation.

3.3. Anwendungsprozess

Die vorgestellten Beispiele haben gezeigt, dass die Anwendungsmöglichkeiten der agentenbasierten Simulation sehr unterschiedlich sind. Auch deshalb liegt der unbefriedigende Schluss nahe, dass sich bei dem aktuellen Forschungsstand auf dem Gebiet der ABS kein detaillierter, allgemeingültiger Anwendungsprozess herausarbeiten lässt. Man kann nur, wie in Abbildung 19 illustriert, einen sehr generischen Prozess definieren (analog zu klassischen Simulationsansätzen, siehe [Law 2007], Kap. 1.7), anhand dessen sich die einzelnen Aspekte der Anwendung dieser Methodik einordnen lassen:




Abbildung 19: Anwendungsprozess einer ABS

Quelle: eigene Darstellung

Der Anwendungsprozess einer ABS beginnt mit der Analyse der zu betrachtenden Problemstellung. Auf Basis der Problemspezifikation erfolgt die Erstellung eines konzeptionellen Modells, welches in einer Programmierungsumgebung implementiert und getestet wird. Zum Ablauf der Simulation sind geeignete Werte für freie Parameter sowohl der Simulation (z. B. Ausgangszustand, Anzahl der Perioden) als auch des zugrunde liegenden Modells (z. B. Gewichte in Entscheidungsregeln, Anzahl der Agenten) zu definieren. Die Erkenntnisse eines Simulationslaufs lassen sich dazu verwenden, gegebenenfalls die Modellierung zu überarbeiten oder die Parametrisierung für einen erneuten Ablauf der Simulation zu modifizieren. Zum Abschluss der Simulationsläufe lassen sich die gewonnenen Ergebnisse zur Beantwortung der initialen Fragestellung aufbereiten. In den folgenden Abschnitten werden diese Schritte detailliert dargestellt und geeignete Umsetzungsmöglichkeiten aufgezeigt. Zur weiteren Vertiefung sei auf [Richiardi et al. 2006] hingewiesen, wo anhand einer umfangreichen Checkliste die einzelnen Schritte zur Erlangung eines sauber implementierten, dokumentierten und getesteten agentenbasierten Simulationsmodells herausgearbeitet werden.

Anwendungen der ABS, insbesondere in der wirtschaftlichen Praxis, sind mit einer speziellen Herausforderung konfrontiert: Ein so komplexes technisches Werkzeug stößt in Unternehmen beinahe zwangsläufig auf Akzeptanzhürden bei den betroffenen Entscheidungsträgern, da die simulierten Zusammenhänge häufig nicht mehr durch grobe lineare Abschätzungen verifizierbar sind. Eine zentrale Aufgabe ist es deshalb, durch vertrauensbildende Maßnahmen die Glaubwürdigkeit der Simulation gegenüber den Entscheidern transparent zu machen (vgl. [Carley 2002] oder [Law 2008]). Geeignete Maßnahmen hierfür sind die Dokumentation der Modellannahmen, die Nachvollziehbarkeit der kausalen Schlüsse sowie die Rückführbarkeit der verwendeten Zahlen auf bekannte Kerngrößen wie Unternehmens- oder Marktzahlen (vgl. [Sterman 2000], Kap. 21.3). Auch eine visuelle Repräsentation des Simulationslaufs (vgl. [Kornhauser et al. 2009] für eine umfassende Diskussion möglicher Visualisierungen) und eine Ablaufprotokollierung sind hilf-

reich für die Überzeugungskraft der Ergebnisse. [Venables und Bilge 1998] stellen sehr anschaulich ein solches Vorgehen für ihr Modell SimStore dar.

3.3.1. Problemanalyse und -spezifikation

Die konkrete Spezifikation des Modells einer ABS hat eine entscheidende Bedeutung, da durch sie die innere Mechanik und die Freiheitsgrade der Simulation bestimmt werden. Dies determiniert auch, welche Forschungsfrage mit der Simulation adressiert werden kann.

Die Arbeit mit Agenten kann in der Problemanalyse auf einen reichen Fundus an Forschung aus der Organisationstheorie zurückgreifen, in der viele Probleme bereits auch mit Bezug auf Agenten untersucht wurden (vgl. [Meyer und Heine 2009] für eine Übersicht). Folgende zentrale Fragestellungen müssen laut [Chang und Harrington 2006] beantwortet werden: Welches Ziel bzw. welchen Zweck verfolgt die Simulation, welchen „Output“ generiert sie? Welche Motivation bzw. Anreize fungieren als „Triebfeder“ des Agentenverhaltens? Wie funktioniert die Allokation von Informationen zwischen der Umgebung und den Agenten, wie zwischen den Agenten untereinander? Wer oder was entscheidet in Konflikt- bzw. Konkurrenzsituationen? Welche Normen und kulturellen Aspekte des realen Systems müssen im Modell berücksichtigt werden?

Zur abstrakten Spezifikation agentenbasierter Modelle haben viele Autoren eigene Ansätze gefunden, ohne dass sich ein allgemein akzeptierter Standard herauskristallisiert hätte. Exemplarisch sei das strukturierte „Five Capabilities“ (5C)-Konzept aus [van Aart 2005] (Kap. 4.2) genannt, das in den fünf abgegrenzten Dimensionen Identität, Kompetenz, Kommunikation, Planung und Umwelt alle für das agentenbasierte Modell relevanten Aspekte berücksichtigt.

In den Übergängen zwischen Spezifikation, Modellierung und Implementierung ergeben sich mögliche Modellierungsalternativen oder konzeptionelle Lücken zum realen System (vgl. [Wilensky und Rand 2007]). Die hierbei verwendeten Annahmen und Vereinfachungen müssen bewusst getroffen und dokumentiert werden, um die logische Nachvollziehbarkeit entlang des Anwendungsprozesses sicherzustellen.

3.3.2. Modellierung

Die ABS kommt häufig mit einer recht einfachen Modellierung der Agenten, ihrer Interaktionen und der Umgebung aus. Verschiedene der im Folgenden aufgezeigten Ansätze gehen jedoch über eine solche Basisanforderung hinaus. So hat der Anwender die Möglichkeit, einfache Modellierungen spezifisch für den anvisierten Einsatzzweck um fortgeschrittenere Ansätze geeignet zu ergänzen.

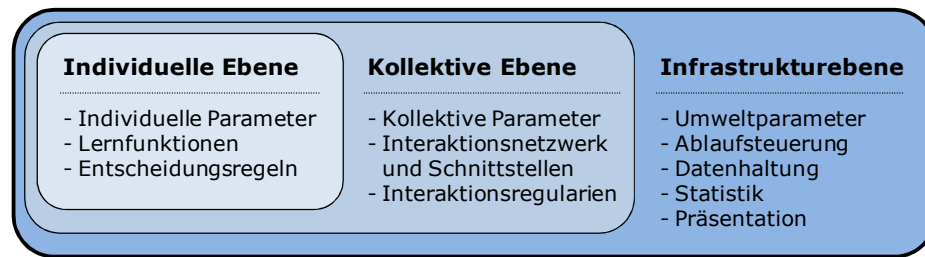


Abbildung 20: Struktur der Modellierung einer ABS

Quelle: eigene Darstellung

Bei der konzeptionellen Modellierung sei im Rahmen der vorliegenden Arbeit (in Anlehnung an [Suematsu et al. 2003]) zwischen der individuellen Ebene, der kollektiven Ebene und der Infrastrukturebene unterschieden (vgl. Abbildung 20).

3.3.2.1. Individuelle Ebene

Um den Zweck als Simulationsbaustein mit eigenständigem, interaktivem Verhalten erfüllen zu können, benötigt ein Agent folgende modelltechnischen Charakteristika: (1) Inputdaten zur Analyse des Simulationszustands, z. B. Informationen über andere Agenten und die Umgebung, (2) Funktionen zur Generierung von Alternativen und darauf aufbauende Entscheidungsregeln, (3) Outputdaten für andere Agenten und die Umgebung sowie (4) Schnittstellen zum Empfang und zur Weitergabe der Daten. Ein Agent bündelt auf diese Weise Daten und Funktionen ähnlich dem Konzept der Kapselung in der objektorientierten Programmierung.

Die direkte Bezugnahme auf individuelle Akteure ermöglicht es, ein breites Spektrum an Verhaltensaspekten in die Modellierung der Agenten einzubeziehen. Wie die in Kapitel 3.2.2 vorgestellten Anwendungsbeispiele zeigen, sind bisher hauptsächlich einfache Entscheidungsregeln verbreitet und auch die theoretische Literatur (vgl. z. B. [Holland 1995], [Wooldridge und Jennings 1995] und [Epstein und Axtell 1996], S. 26 ff.) setzt sich grundlegend mit dieser Art der Verhaltensmodellierung auseinander. Lassen sich die Simulationszustände für die Verankerung von Regeln nur unscharf definieren (wie „auskömmlicher“ Ertrag oder „niedrige“ Kosten), so stellen Fuzzylogic-Regelsysteme wie von [Lusch und Tay 2004] gezeigt eine Möglichkeit zur Modellierung dar. Alternativ zu deterministischen Entscheidungsregeln können auch Wahrscheinlichkeiten für die Auswahl der Alternativen definiert werden (wie im Falle des im Folgenden näher beschriebenen bestärkenden Lernens); die Agenten entscheiden dann stochastisch entlang dieser Wahrscheinlichkeiten (zur Modellierung diskreter Entscheidungen siehe [Gönsch et al. 2008], im Kontext einer ABS siehe z. B. [Benenson und Torrens 2004], Kap. 5.5).

Erfolgt die Auswahl einer Alternative nicht nur auf Basis einer Auswertung des aktuellen Simulationszustands, sondern bezieht auch vergangene Zustände mit ein (analog zu einer Historie oder einem Gedächtnis im realen System), so müssen Informationen hierzu in einem sogenannten internen Zustand des jeweiligen Agenten oder in einem zentralen Repository gespeichert werden. Diese können dann mittels einer Lernfunktion ausgewertet werden (vgl. [Weidlich 2008], Kap. 4). Das Ziel bei dem Einsatz einer ABS ist dabei normalerweise nicht,

möglichst intelligente Agenten zu entwickeln, sondern Agenten interagieren zu lassen, die ein möglichst einfaches, aber auch realistisch-intelligentes Verhalten zeigen.

Ein grundlegendes Konzept stellt das bestärkende Lernen („reinforcement learning“, siehe [Brenner 2006]) dar. Es ermöglicht eine intuitive, quasi-automatisch ablaufende Reaktion auf ein Ereignis. Die Auswahl zwischen verschiedenen Entscheidungsalternativen erfolgt hierbei nicht deterministisch, sondern stochastisch anhand von Wahrscheinlichkeiten, die auf der Basis vergangener Erfahrungen wie Belohnungen oder Bestrafungen in vergleichbaren Situationen manifestiert wurden. Die Modellierung gestaltet sich recht einfach: Alle möglichen Handlungsalternativen der Agenten werden mit Entscheidungswahrscheinlichkeiten hinterlegt. Diese werden im Laufe der Simulation anhand der Erfahrungen des Agenten modifiziert, sodass positiv erfahrenes Verhalten zukünftig bevorzugt ausgewählt wird. Verschiedene Möglichkeiten zur Modifikation der Wahrscheinlichkeiten stellt [Marks 2006] im Detail dar.

3.3.2.2. Kollektive Ebene

Auf der kollektiven Ebene werden Aspekte modelliert, die sich auf die Gesamtheit der Agenten beziehen (z. B. deren Anzahl) oder deren Interaktionsverhalten adressieren.

Um in Interaktion treten zu können, benötigen Agenten Schnittstellen zum Informationsaustausch. Diese können rein auf technischer Ebene die Infrastruktur für die Interaktion darstellen oder zusätzliche Funktionen wie z. B. die Filterung oder Aufbereitung von Informationen wahrnehmen.

Die gebräuchlichste Form der Interaktion zwischen Agenten ist die Kommunikation. Bei dieser werden Informationen gemäß eines Standards oder einer bilateralen Übereinkunft zwischen den Agenten codiert und übertragen. Einfache Kommunikation kann hierbei über standardisierte Schnittstellen und Sprachen erfolgen, für komplexe Kommunikationsstränge werden gemeinsam genutzte Ontologien für die verwendeten Sprachen und Protokolle benötigt.

Direkte Interaktion findet in einem lokal strukturierten Kontext statt. Dieser kann räumlicher, sozialer, institutioneller oder auch organisatorischer Natur sein (vgl. [Dibble 2006]). Allgemein bezeichnet man diesen Raum, der die Interaktion zwischen den Agenten ermöglicht, als die *Nachbarschaft* eines Agenten. Üblicherweise wird die Nachbarschaft gebildet durch die Menge anderer Agenten, die ein Agent in sein Entscheidungsverhalten mit einbezieht. In der *Topologie* der Interaktion wird diese Nachbarschaft modelltechnisch durch die Auswahl, Struktur und Anordnung der Schnittstellen definiert (vgl. [North und Macal 2007], S. 198 ff.). Sie begrenzt den Informationsfluss zwischen Agenten – nicht jeder weiß alles – und beeinflusst somit deren Entscheidungen und Aktivitäten (vgl. [Wilhite 2006]).

Entsprechend hat sie einen entscheidenden Einfluss auf den Ablauf und die Ergebnisse einer Simulation, wie beispielsweise [Rahmandad und Sterman 2008] anschaulich zeigen.

Typischerweise werden Topologien durch Verbindungsnetzwerke modelliert (z. B. in [Epstein und Axtell 1996], S. 7). Diese Verbindungen können entweder statisch vordefiniert sein (exogen) oder dynamisch zur Laufzeit generiert werden (endogen). Häufig tragen die Verbindungen noch weitere Attribute (z. B. eine Länge), welche einen Einfluss auf das darüber abgewickelte Interaktionsverhalten haben. Exogene Verbindungsnetzwerke werden

vor Ablauf einer Simulation generiert und lehnen sich oftmals an real existierende Strukturen wie soziale Netzwerke (z. B. Nachbarschaften oder Peergroups), Lieferketten oder Organisationsstrukturen an (siehe [Chang und Harrington 2006] sowie [Wilhite 2006]). Endogene Verbindungsnetzwerke werden hingegen zur Laufzeit entweder zufällig ermittelt oder aber durch dynamisches Agentenverhalten wie z. B. durch soziale Interaktion generiert. Einen speziellen Fall stellen räumliche Verbindungen dar. Bei diesen leitet sich aus der Position eines Agenten im Raum automatisch dessen Nachbarschaft ab. Die ABS kann aus dieser Perspektive als eine Erweiterung des Simulationskonzepts zellulärer Automaten (vgl. [Bossomaier 2008]) um eine komplexere Umgebung, vielschichtige Interaktionsmöglichkeiten sowie höher entwickelte Fähigkeiten der Agenten betrachtet werden (vgl. [Klügl 2000], Kap. 3.2.2). Beispielsweise kombinieren Geoinformationssysteme (GIS, siehe [Gilbert 2007], Kap. 5.1, oder [Castle und Crooks 2006], Abs. 1.3) räumliche Aspekte und verbindungs-basierte Graphen miteinander. Die Umgebung und die Verbindungen zwischen Agenten haben dabei räumliche Attribute und die Agenten zeigen ein räumliches Verhalten wie z. B. eine Bewegung in ihrer Umgebung. Durch die Integration von Positionsdaten und Kontextattributen wie demografischen oder geologischen Daten können solche Simulationen besonders realitätsnah gestaltet und auf realem Kartenmaterial visualisiert werden (wie bei [Benenson und Torrens 2004] oder bei [Brown et al. 2005] gezeigt wird).

Im Gegensatz zur direkten Interaktion beinhaltet die ABS aber auch die Möglichkeit der indirekten Interaktion zwischen Agenten. Diese findet schon allein dadurch statt, dass Agenten im Rahmen eines Verhaltensschritts den Simulationszustand ändern, was sich auf das darauffolgende Verhalten der übrigen Agenten auswirken kann. Darüber hinaus können Agenten über eine Interaktion mit der Umgebung Informationen untereinander austauschen. Ein typisches Beispiel einer solchen indirekten Kommunikation stellt [LeBaron 2006] vor, wo auf Märkten die Preise (und andere Umgebungsvariablen) für einen Informationsfluss zwischen Agenten sorgen.

3.3.2.3. Infrastrukturebene

Die Umgebung in einem agentenbasierten Modell beschreibt alle Aspekte, die nicht den Agenten zugerechnet werden können (vgl. [Weyns et al. 2007]). Sie dient als Infrastruktur für die Agenten und beinhaltet grundlegende Simulationsfunktionen und -parameter, die nicht im Rahmen der Agenten abzubilden sind. Hierzu gehört insbesondere die Ablaufsteuerung der Simulation, durch welche die Abfolge der Aktionen der einzelnen Agenten geregelt wird (vgl. [Gilbert 2007], Kap. 2.4.1) und die als globaler Koordinierungs- und Synchronisationsmechanismus fungiert. Die Zeit innerhalb der Simulation ist hierbei üblicherweise asynchron zur realen Zeit und wird über einen separaten Zeitzähler in der Ablaufsteuerung abgebildet. Dadurch können Abläufe im Zeitraffer simuliert oder auch in Zeitlupe analysiert werden. Im Rahmen der Infrastruktur kann auch eine übergreifend genutzte Datenhaltung modelliert werden, außerdem findet man hier die grafische Oberfläche und Präsentationselemente der Simulation wie Diagramme oder Schaubilder.

3.3.2.4. Modellierungssprachen

Der gebräuchlichste Standard zur Modellierung agentenbasierter Systeme ist Agent UML (AUML²²). Dieser entstand aus einer Kooperation der Foundation of Intelligent Physical Agents (FIPA²³) und der Object Management Group (OMG²⁴), welche als Industriekonsortium für die Weiterentwicklung der Unified Modeling Language (UML) als dem de-facto Standard für objektorientierte Softwareentwicklung zuständig ist. AUML ist mit einer Abdeckung des gesamten Software-Lebenszyklus vor allem auf professionelle industrielle Applikationen ausgerichtet (vgl. [Bauer et al. 2001]). Aktuelle Entwicklungen deuten außerdem auf eine direkte Integration agentenbasierter Modellierungsansätze in die UML-Spezifikation hin (vgl. [Bauer und Odell 2005]).

Neben AUML haben sich viele weitere Ansätze zur Modellierung von Agentensystemen entwickelt. [Cervenka und Trencansky 2007] bieten eine Übersicht und stellen mit AML (Agent Modeling Language) einen fortgeschrittenen Ansatz vor. Aufbauend auf Best-practice-Erfahrungen mit anderen Modellierungswerkzeugen wie dem vorgestellten AUML wird eine Modellierungssprache mit dem Ziel entwickelt, die gesamte Prozesskette der agentenorientierten Softwareentwicklung von der Spezifikation bis hin zur Dokumentation abzudecken. Auch die Sprache SESAM (vgl. [Oechslein 2004], Kap. 6) bietet einen ähnlich weitreichenden Funktionsumfang.

3.3.3. Implementierung und Test

Da technische Implementierungsaspekte wie Ablaufreihenfolgen oder die Generierung von Zufallszahlen einen Einfluss auf das Simulationsverhalten haben können, ist erst die Implementierung selbst und nicht das Modell an sich die vollständige Spezifikation einer ABS (vgl. [Dibble 2006]). In [Axtell et al. 1996] und [Wilensky und Rand 2007] befassen sich die Autoren explizit mit dieser Thematik und vergleichen die Implementierung identischer konzeptioneller Modelle in unterschiedlichen Agentenumgebungen.

Wie auch bei der klassischen Softwareentwicklung beginnt die Implementierung eines agentenbasierten Modells in der Regel mit der Erstellung eines Prototyps, welcher einen reduzierten Funktionsumfang aufweist und häufig auch nur in einer vereinfachten Umgebung erstellt wird. Nach dem erfolgreichen Machbarkeitsnachweis wird eine vollumfängliche Implementierung gestartet. Generell bewährt hat sich ein sukzessives Vorgehen, beginnend mit einem einfachen Modell werden dabei immer weitere Details hinzugefügt. So entsteht die Kombination aus Top-down- und Bottom-up-Entwicklung: Ausgehend von einem groben Modell werden die Annahmen immer weiter verfeinert, wobei zu jedem Zeitpunkt die Einbeziehung von Detailspekten möglich ist. Die folgenden Abschnitte werden dazu verwendet, gebräuchliche Ansätze und Werkzeuge für eine solche Implementierung vorzustellen.

²² <http://www.auml.org/>, abgerufen am 28. Februar 2009.

²³ <http://www.fipa.org/>, abgerufen am 28. Februar 2009.

²⁴ <http://www.omg.org/>, abgerufen am 28. Februar 2009.

Die Softwarelandschaft zur Unterstützung der agentenbasierten Modellierung, Programmierung und Simulation ist divers, nicht zuletzt auch aufgrund der schon erwähnten geringen Marktdurchdringung von Standardansätzen. Eine umfassende Übersicht findet sich bei [Nikolai und Madey 2009], detailliertere Betrachtungen in [Oechslein 2004] (Kap. 8) sowie in [Unland et al. 2005].

Vor allem im akademischen Umfeld haben sich integrierte Entwicklungs- und Simulationsumgebungen etabliert, die Forschern einen One-stop-Shop zur agentenbasierten Modellierung und Simulation bieten (vgl. [Railsback et al. 2006]). Häufig werden die aus Forschungsprojekten hervorgegangenen, frei verfügbaren Umgebungen Swarm²⁵ und Repast²⁶ eingesetzt. Diese Softwaresysteme mit grafischer Oberfläche bieten vordefinierte Elemente zur Modellierung und eine Laufzeitumgebung zur Durchführung der Simulation. Über Programmierschnittstellen kann eigener Code in die jeweilige Implementierung integriert werden. Für den industriellen wie auch akademischen Einsatz wird außerdem die kommerzielle Simulationsumgebung AnyLogic²⁷ angeboten. Diese hat den zuvor genannten Systemen neben einer benutzerfreundlicheren Oberfläche und Dokumentation auch die Integration von Optimierungsalgorithmen und Schnittstellen zu gebräuchlichen IT-Systemen voraus. Deshalb wird diese Software auch für die Implementierung des agentenbasierten Modells des Mobilfunkmarktes später in Kapitel 4.6 der vorliegenden Arbeit eingesetzt.

Direkt an die Implementierung eines Modells schließen sich die Verifikation (Test auf korrekte programmtechnische Umsetzung des konzeptionellen Modells bzw. der Spezifikation) und die Validierung (Test auf Konsistenz mit beabsichtigtem bzw. erwartetem Verhalten bzgl. einer konkreten Problemstellung) an, bevor ein Modell als produktives Simulationswerkzeug eingesetzt werden kann (siehe [Balci 1998], [Xiang et al. 2005], [Gilbert 2007], Kap. 3, [Midgley et al. 2007] und [Sargent 2007]). Eine umfangreiche und praxisnahe Diskussion der in diesen beiden Phasen häufig identifizierten Fehler und Unregelmäßigkeiten bieten [Galán et al. 2009]. Die Verifikation agentenbasierter Simulationen gestaltet sich schwieriger als bei der traditionellen Softwareentwicklung, da aufgrund der Emergenzeigenschaft kaum Testfälle für „korrektes“ makroskopisches Modellverhalten zur Verfügung stehen. Schon [von Hayek 1972] (Kap. 3) bemerkt in einem vergleichbaren Kontext, dass beim Umgang mit komplexen Phänomenen auch umgekehrt eine Falsifizierung entwickelter Theorien häufig nicht möglich ist. Einfacher ist jedoch die Validierung. Hierbei gilt es zu überprüfen, ob die Simulation einen mit dem realen System vergleichbaren Ablauf zeigt, z. B. historische Daten adäquat repliziert (vgl. [LeBaron 2006]). Diese empirische Überprüfung sollte, wie in [Midgley et al. 2007] näher ausgeführt, auf zwei Ebenen erfolgen, sowohl auf der Mikroebene des Agentenverhaltens als auch auf der aggregierten Makroebene. Bei beidem ist die Einbeziehung von Fachexperten hilfreich, die grundlegende Annahmen, den Ablauf der Simulation sowie die Ergebnisse kritisch anhand ihrer Erfahrungen mit dem realen System beurteilen können (siehe [Veit 2006], Kap. 3, [Munroe et al. 2006] oder

²⁵ <http://www.swarm.org/>, abgerufen am 28. Februar 2009.

²⁶ <http://repast.sourceforge.net/>, abgerufen am 28. Februar 2009.

²⁷ <http://www.anylogic.com/>, abgerufen am 28. Februar 2009.

[Law 2008]). Zwar sind solche Experten oft nicht in der Lage, explizite Regeln oder quantitative Parameterwerte aus dem System abzuleiten, eine qualitative Beurteilung von Ergebnissen hinsichtlich deren Plausibilität ist aber deutlich einfacher. [Pidd 2010] weist zu Recht darauf hin, dass der Grad der Validierung eines Modells von der beabsichtigten Anwendung abhängig sein sollte. Entsprechend sind die höchsten Anforderungen an die Modellvalidierung zu stellen, wenn die Simulationsergebnisse als Parameter direkt in einen realen Prozess übernommen werden.

3.3.4. Parametrisierung und Ablauf der Simulation

Bei der Parametrisierung der Simulation wird definiert, welche Werte für die nicht veränderlichen Parameter sowie als Initialisierungswerte für Modellvariablen verwendet werden. Idealerweise lassen sich solche Werte wie z. B. die Anzahl der simulierten Agenten oder deren demografische Daten aus dem realen System direkt ableiten, schätzen oder unter Zuhilfenahme von Fachexperten ermitteln. Auf diese Weise können freie Parameter des Simulationsmodells unter Bezugnahme auf das reale System kalibriert werden. [Darley und Outkin 2007] gehen intensiver auf die Thematik einer solchen Kalibrierung ein und zeigen in einem Beispiel, wie die Kalibrierung ihres agentenbasierten Finanzmarktmodells anhand realer Handelsvolumina und dem empirisch untersuchten Verhalten von Händlern erfolgen kann.

Die Sensitivitätsanalyse gibt anschließend Aufschluss darüber, welche Parameter einen Einfluss auf die Ausprägung des Simulationsergebnisses haben (Test auf Signifikanz) bzw. wie sich leichte Veränderungen der Parameter auf das Simulationsergebnis auswirken (Test auf Robustheit bzw. auf plausible Veränderung der Ergebnisse, siehe [Richiardi et al. 2006] oder [Rahmandad und Sterman 2008]). Oft haben freie Parameter einen großen Einfluss auf das Ergebnis der Simulation, da die emergenten Auswirkungen von Veränderungen der Parameter nicht a priori ersichtlich sind und zu chaotischen Effekten führen können. Indikationen zur Robustheit der aus der Simulation abgeleiteten Aussagen lassen sich dadurch treffen, dass man die Wertebereiche der Parameter ermittelt, innerhalb derer das zentrale Resultat gültig bleibt (vgl. [Miller 1998]). Eine Anwendung der Sensitivitätsanalyse könnte z. B. Aufschluss darüber geben, wie elastisch die aggregierte Kundennachfrage nach einem Mobilfunktarif auf leichte Veränderungen im verlangten Preis reagiert, wie in Kapitel 8.1 an einem Fallbeispiel gezeigt wird.

Bei der Optimierung werden die Parameter der Simulation selbst zu Variablen in einem Optimierungsalgorithmus (siehe z. B. [Spall 2003]). Unter Anwendung heuristischer Verfahren wie der Tabusuche (siehe [Glover und Laguna 1997]) oder genetischer Algorithmen (siehe [Goldberg 1989]) wird hierbei versucht, dem Forschungsziel entsprechend möglichst gute Kandidaten für Ausprägungen von Parametern zu finden, welche in der Simulation eine hohe Übereinstimmung mit einer realen Marktentwicklung zeigen oder allgemein ein gewünschtes Makroverhalten hervorrufen. So lassen sich z. B. für einen Mobilfunkbetreiber die Preise seines Vertragsportfolios so optimieren, dass ein möglichst großer Umsatz oder Gewinn erzielt wird. Beginnend mit Kapitel 5 beschäftigt sich die vorliegende Arbeit intensiv mit der Thematik der Optimierung einer ABS.

3.3.5. Analyse und Aufbereitung der Ergebnisse

Da die Datenbasis einer ABS sehr feingranular auf der Ebene einzelner Agenten zur Verfügung steht, müssen die Ergebnisse in Abhängigkeit von dem zugrunde liegenden Problem geeignet zu relevanten Aussagen verdichtet werden. Diese Verdichtung kann durch Selektion, Aggregation oder mithilfe statistischer Kennzahlen und Analysen erfolgen. Bei Modellen zur Entscheidungsunterstützung finden die Parameter eines erfolgreichen Simulationslaufs oft Eingang in die operative Umsetzung, z. B. die Preisgestaltung eines neuen Mobilfunktarifs, welche sich in der Simulation als gewinnmaximierend herauskristallisiert hat. Bei Markt- und Organisationsmodellen steht hingegen eher die statistische Auswertung mehrerer Simulationsläufe im Vordergrund. Mögliche Erkenntnisse wären beispielsweise, dass ein bestimmtes Tarifportfolio für einen Mobilfunkbetreiber bei über 80 % der stochastischen Simulationsläufe zu einer Dominanz im Marktanteil gegenüber den Wettbewerbern führt.

3.4. Zusammenfassung und Ausblick

In diesem Kapitel wurde die ABS als ein Werkzeug vorgestellt, mit dem sich Einblicke in eine Vielzahl betriebswirtschaftlicher Problemstellungen gewinnen lassen. Dieses Werkzeug eignet sich insbesondere für Systeme, die von Heterogenität, Netzwerkeffekten und Emergenz aufgrund komplexer Interaktionen der Akteure geprägt sind. Das individuelle Verhalten der Agenten wurde als das zentrale Element der Simulation identifiziert, und es wurden relevante Verhaltensaspekte herausgearbeitet. Akademische wie auch praktische Anwendungen der ABS fanden sich insbesondere in der Energie- und Finanzwirtschaft sowie in den Wirtschaftszweigen Produktion, Logistik und Handel, vereinzelt auch in anderen Bereichen. Den Arbeiten ist gemein, dass sich keine übergreifend akzeptierten Ansätze herauskristallisieren, sondern jeweils eigenständige Konzepte entwickelt und angewendet werden. Abschließend wurde auf die praktische Anwendung agentenbasierter Simulationen eingegangen, insbesondere wurden hierbei verschiedene Modellierungsmöglichkeiten vorgestellt.

Das noch recht junge Forschungsfeld der ABS bietet eine Vielzahl von Ansatzpunkten für zukünftige Arbeiten. Für betriebswirtschaftliche Anwendungen bietet sich unter anderem das Marketing an, da auf dem Wege der agentenbasierten Modellierung explizit auf die fortschreitende Individualisierung in der Produkt- und Preisgestaltung sowie in der Kundenansprache eingegangen werden kann. Im weiteren Verlauf dieser Arbeit wird z. B. eine solche Anwendung zur Preisoptimierung im Mobilfunk vorgestellt. Auch im Supply Chain Management gewinnt die Analyse des komplexen Zusammenspiels unterschiedlicher Akteure innerhalb von Prozessen zunehmend an Bedeutung, bedingt durch die Verbreitung von Outsourcing sowie durch den Übergang von hierarchischen Unternehmensstrukturen hin zu vernetzten Matrixorganisationen. Schließlich haben die disruptiven Ereignisse jüngst in der Finanzbranche gezeigt, dass die marktbasierende Bewertung von Bilanzpositionen stark von der dynamischen Interaktion der auf dem Markt handelnden Akteure abhängt. Für eine Analyse der Effekte solcher Wirkungszusammenhänge ist die ABS ein hilfreiches Werkzeug mit erheblichem Potenzial.

4. Agentenbasierte Modellierung und Simulation eines Mobilfunkmarktes

In diesem Kapitel wird zur Verdeutlichung der in Kapitel 3.3 vorgestellten Methoden ein Mobilfunkmarkt als ABS modelliert. Diese Simulation stellt einen prototypischen, exemplarischen Anwendungsfall der ABS dar und ist insbesondere dazu bestimmt, eine praxisnahe Grundlage für die Erprobung verschiedener Verfahren der simulationsbasierten Optimierung in den Kapiteln 7 und 8 zu bilden. Da die vorgestellte Simulation aufgrund der Komplexität des zugrunde liegenden Mobilfunkmarktes und der lückenhaften Datenlage nicht alle Facetten des Marktes realitätsgetreu abbilden kann, erhebt sie nicht den Anspruch, ein anwendbares Decision-Support-System zur Unterstützung von Managemententscheidungen zu sein. Bei einer weiteren Ausgestaltung des Modells ließe sich die ABS aber durchaus dazu verwenden, Mobilfunkunternehmen bei Entscheidungen des Preismanagements zu unterstützen. Typische Fragestellungen wären hierbei dann, welche Marktentwicklungen die Preisentscheidung eines Mobilfunkanbieters hervorrufen kann (z. B. einen sukzessiven Preiskampf der Anbieter), welche Umsätze und Profitabilität mit einem bestimmten Tarifportfolio erzielt werden können oder welcher Markterfolg für einen neuen Tarif im Wettbewerb mit bereits am Markt etablierten Tarifen erwartet werden kann.

Der Mobilfunk ist allgemein betrachtet eine prädestinierte Domäne für die ABS (wie auch [Schnorf 2008] bemerkt), da ein Mobiltelefon als persönlicher Gegenstand einer einzelnen Person eindeutig zugeordnet werden kann. Somit sind die Mobilfunknachfrage und die Interaktionen im Markt durch ein abgrenzbares individuelles Verhalten bestimmt, im Gegensatz z. B. zum Festnetz, wo in der Regel ein Anschluss pro Haushalt existiert und damit lediglich das Verhalten potenziell mehrerer Personen aggregiert betrachtet werden kann.

4.1. Simulationsmodell und -komponenten

Der im Folgenden beschriebene Entwurf eines agentenbasierten Simulationsmodells in Anlehnung an den deutschen Mobilfunkmarkt basiert auf zwei grundlegenden Leitgedanken: der Abstraktion sowie der konsistenten Detailtreue.

Eine Simulation geht immer von einem Modell der Realität aus, welches per Definition eine gewisse Abstraktion desselben darstellt. Dies ist also bereits in der Problemstellung verankert und eine zentrale Notwendigkeit der wissenschaftlichen Arbeit. Schon [Rosenblueth und Wiener 1945] beschreiben treffend, dass kein substanzieller Teil des Universums einfach genug ist, dass man ihn ohne Abstraktion erfassen und verstehen könnte. Ein Modell ohne Abstraktion entspricht dem realen System und ist damit per se ohne zusätzlichen Nutzen. Sinn und Zweck der Abstraktion ist es also, durch Vereinfachungen und andersartige Darstellung von Dingen, Vorgängen und Zusammenhängen das reale System anhand des Modells einfacher begreifbar zu machen.

Die Charakteristik eines komplexen Marktes wie dem Mobilfunkmarkt verhindert außerdem die detailgetreue Abbildung der Realität. Hierzu fehlt es an Erkenntnissen z. B. über das

konkrete, individuelle Entscheidungsverhalten der vielen Millionen Marktteilnehmer. Da dieses jedoch, wie in Kapitel 3.1.2 herausgearbeitet wurde, die zentrale Triebfeder der Systemdynamik darstellt, bestimmt die erzielbare Detailtreue bei diesem Sachverhalt auch die maximal sinnvolle Detailtreue bei anderen Aspekten der Modellierung. Ziel sollte also eine über alle modellierten Aspekte hinweg konsistente Detailtreue bzw. in diesem Fall äquivalent ein konsistenter Abstraktionsgrad sein. Letztendlich gilt es bei einer Simulationsstudie, den minimalen Detailgrad zu erzielen, der notwendig ist, um das zu studierende Systemverhalten nachzubilden (vgl. [Grimm et al. 2005] oder [Bossel 2004], Kap. 1.3). Eine höhere Modellkomplexität würde zwar ein der Realität scheinbar näheres Modell ermöglichen, dieses wäre aber in der Anwendung eher undurchschaubar und in seinen Ergebnissen damit weniger nachvollziehbar (vgl. z. B. [Midgley et al. 2007]).

Konkret wird in der vorliegenden Arbeit auf Basis einer breiten Auswahl an empirischen wie auch theoretischen wissenschaftlichen Studien ein abstraktes Verhaltensmodell abgeleitet und verwendet. Vereinfachungen sind hierbei unumgänglich, diese werden durch explizite Annahmen dokumentiert. Alle Aspekte des Modells werden mit einem vergleichbaren Realitätsgrad abgebildet, so wird z. B. die unüberschaubare Vielfalt der am Markt existierenden Tarife durch ein abstraktes Portfolio an verbreiteten Tariftypen repräsentiert.

Die Validierung (vgl. Kap. 3.3.3) des so konstruierten Modells gestaltet sich schwierig, da weder auf der Mikroebene ein geschlossenes Verständnis der Verhaltensmechanismen der handelnden Akteure existiert, noch auf der Makroebene aufgrund getroffener Vereinfachungen ein vergleichbares System vorliegt, das empirische Daten zum Vergleich liefern könnte. Deshalb wird in der vorliegenden Arbeit, wie auch von [Jäger et al. 2000] vorgeschlagen, der Ansatz verwendet, die mikroskopischen Verhaltensregeln der einzelnen Agenten mithilfe der existierenden Forschung zu individuellem Entscheidungsverhalten zu validieren. Zusätzlich wird eine makroskopische Validierung anhand prinzipieller Analogien der beobachtbaren Effekte zwischen der Simulation und dem zugrunde liegenden deutschen Mobilfunkmarkt durchgeführt.

Das vorgestellte Modell bildet einen generischen Mobilfunkmarkt mit den typischen Tarifkonstrukten ab, wie er sich in vielen Ländern Europas im Laufe der Entwicklung hin zum Massenmarkt etabliert hat. Zwei Typen von Akteuren seien unterschieden: Netzbetreiber als Mobilfunkanbieter sowie Kunden, die Mobilfunk-Sprachtelefonie nachfragen. Die Ausgestaltung der Anbieter im Hinblick auf deren Marktpositionierung sei hierbei an den deutschen Mobilfunkmarkt angelehnt. Den Anbietern ist jeweils ein Portfolio an angebotenen Tariftypen vorgegeben, deren Preisstruktur sich vom Benutzer für die Simulation parametrisieren lässt. Die Kunden zeigen ein an ihrer individuellen Situation ausgerichtetes Entscheidungsverhalten, das signifikant von den Entscheidungen anderer Kunden abhängt und deutlich heterogen ausgeprägt sein kann. Durch die komplexen Wechselwirkungen, insbesondere im Rahmen von Community-Rabatten (vgl. Kap. 2.1.4), entstehen Netzwerkeffekte mit emergenten Wirkungsketten, die eine wirtschaftliche Beurteilung der Preise einzelner Anbieter im Kontext des Gesamtmarktes mit einfachen Mitteln häufig unmöglich machen. Folglich können die Auswirkungen der festgelegten Preisstruktur eines Anbieters

erst mit dem Ablauf der Simulation anhand erzielter Umsätze, Kundenzahlen und Marktanteile analysiert werden.

In den folgenden Unterkapiteln werden die Modellierung der Anbieter und Tarife (Kap. 4.2) wie auch der Kunden (Kap. 4.3) näher beschrieben und dabei insbesondere auf das Entscheidungsmodell der Kunden, deren Netzwerk der sozialen Interaktion sowie deren sonstige Nachfrage- und Präferenzcharakteristika eingegangen. Bei der Beschreibung des Simulationsmodells orientiert sich diese Arbeit an den von [Richiardi et al. 2006] angeregten Richtlinien, deren Einhaltung eine hinreichende Dokumentation zur Nachvollziehbarkeit der Modellierung und der abgeleiteten Ergebnisse sicherstellen soll. An verschiedenen Stellen wird auf zu definierende Parameter des Modells hingewiesen, eine für die späteren Simulations- und Optimierungsstudien verwendete konkrete Parametrisierung findet sich im weiteren Verlauf dieser Arbeit in den Kapiteln 4.6 bzw. 7.1.

Die Zeitsteuerung der Simulation des Mobilfunkmarktes erfolgt im Modell periodengestützt mit einer zu definierenden Anzahl an Modellperioden. Die Simulation unterliegt verschiedenen stochastischen Einflüssen, die als Zufallsvariablen modelliert sind und durch einen Pseudozufallszahlengenerator gespeist werden. Stochastische Modellkomponenten finden sich sowohl bei der Initialisierung als auch im Ablauf der Simulation: Im Rahmen der Modellinitialisierung werden die Netzwerkverbindungen der einzelnen Kunden, deren Zugehörigkeit zu einem Kundensegment, deren Nachfrage sowie deren initiale Ausstattung mit einem Mobilfunktarif stochastisch bestimmt (vgl. Kap. 4.4). Außerdem wird während der Simulation jede Entscheidung eines Agenten durch eine additive stochastische Störkomponente beeinflusst (vgl. Kap. 4.3.1). Durch diese eingebauten Zufallskomponenten ist der Ausgang eines Simulationslaufs trotz vorgegebener Parameterwerte nicht deterministisch festgelegt und kann in einzelnen Fällen sogar eine erhebliche Varianz aufweisen (vgl. Kap. 6.1).

Ähnliche Modellierungsansätze finden sich in der Literatur vor allem in einer Vielzahl von Studien über die Diffusion eines neuen Produkts in einen Markt (siehe z. B. [Mahajan et al. 2000] oder [Schnorf 2008]). Hierbei wird insbesondere die Vernetzung der Kunden untereinander modelliert und häufig wird auch von heterogenen Kunden ausgegangen. Von diesem Strang der Forschung grenzt sich die vorliegende Arbeit dadurch ab, dass die Konkurrenz mehrerer Produkte am Markt berücksichtigt wird. Außerdem beschränkt sich das Modell dieser Arbeit nicht nur auf die Analyse der Neueinführung eines Produkts am Markt, sondern lässt sich auch im Kontext der preislichen Repositionierung eines bereits existierenden Produkts anwenden. Die hierbei untersuchten Marktmechanismen sind zwar vergleichbar mit Diffusionsstudien, nicht jedoch die Untersuchungsgegenstände: Während die Diffusionsforschung in der Regel die Anzahl der verkauften Einheiten betrachtet, steht der Verkaufspreis dieser Güter im Fokus der vorliegenden Untersuchung, welcher aggregiert den Umsatz der Anbieter darstellt.

Beispielsweise verwendet [Liehr 2005] (Kap. E.3) in seiner Diffusionsstudie eine ABS, um den potenziellen Markterfolg eines Mobiltelefons mit eingebauter Kamera zu untersuchen. Allerdings gibt es hier keine konkurrierenden Produkte am Markt. Somit existiert keine echte Auswahlentscheidung der Kunden. Das Forschungsinteresse bezieht sich vielmehr auf

die Adoption des neuen Produkts und die hieraus aggregiert resultierende Diffusion in den Markt. Die Simulation dient dazu, aus Sicht des Anbieters verschiedene Möglichkeiten des Preismanagements durchzuspielen und deren Ergebnisse zu analysieren. Der Autor untersucht hierzu die Auswirkungen von im Zeitverlauf konstanten Preisen ebenso wie die Effekte zeitlicher Preisdifferenzierung durch eine Penetrationsstrategie (im Zeitverlauf steigende Preise) oder eine Skimming-Strategie (fallende Preise). Eine ebenfalls analysierte kundenbezogene Preisdifferenzierung zeigt sich interessanterweise nicht erfolgversprechend, da die hiermit adressierten gut vernetzten Personen unabhängig von gewährten Rabatten aufgrund ihrer Position im Netzwerk sowieso zu den ersten Kunden zählen, dann aber einen geringeren Preis zahlen würden. Ihren positiven Einfluss auf die Tarifentscheidungen ihrer Nachbarn im Netzwerk spielen diese Kunden jedoch in beiden Fällen unabhängig von dem gewährten Rabatt aus.

4.2. Modellierung der Anbieter und Tarife

Auf dem modellierten Mobilfunkmarkt wird Sprachtelefonie als Produkt angeboten und nachgefragt, ohne Berücksichtigung mobiler Datendienste (wie z. B. auch bei [Stingel 2008], Kap. 5). Damit wird bereits ein großer Teil des Mobilfunkmarktes abgedeckt (vgl. Statistiken in Kap. 2.1), zudem handelt es sich bei der Sprachtelefonie um ein homogenes, zwischen verschiedenen Anbietern gut vergleichbares Produkt. Als Abrechnungseinheit hierfür sei die Gesprächsdauer in Minuten verwendet.

In Anlehnung an den deutschen Mobilfunkmarkt werden vier MNOs berücksichtigt (vgl. Kap. 2.1.1), die sich in ihrer Parametrisierung (vgl. Kap. 7.1) an den realen Anbietern orientieren: Anbieter \mathbb{A} (vgl. T-Mobile), Anbieter \mathbb{B} (vgl. Vodafone), Anbieter \mathbb{C} (vgl. E-Plus) und Anbieter \mathbb{D} (vgl. O₂). Auf eine Einbeziehung von Service Providern und MVNOs sei verzichtet (analog zu [Doganoglu und Grzybowski 2007]), da sich diese ohne Erkenntnisverlust für die durchgeführte Analyse den Netzbetreibern zurechnen lassen, die das jeweilige Angebot netzwerkseitig betreiben.

Es sei davon ausgegangen, dass (wie in Kap. 2.1.1 ausgeführt) die Anbieter hauptsächlich mit fixen Kosten konfrontiert sind, welche für die kurz- bis mittelfristige Preisoptimierung als sogenannte „sunk cost“ keine entscheidungsrelevante Rolle spielen. Die Anbieter werden im Modell deshalb lediglich umsatzseitig betrachtet, eine Aufrechnung gegen die zur Erbringung des Angebots notwendigen Kosten findet nicht statt. Implizit bedeutet dies, dass jeder der Netzbetreiber genügend Kapazität in seinem Netz bereithält, um auch eine steigende Nachfrage ohne zusätzliche strukturelle Investitionen bedienen zu können. Historisch betrachtet entspricht diese Annahme auch den Gegebenheiten am Markt, bis auf einzelne regionale Netzengpässe während der Aufbauzeit von E-Plus und O₂ konnte die Nachfrage der Kunden meistens problemlos aufgrund eines kontinuierlichen, nicht durch kurz- bis mittelfristige Nachfrageplanung bedingten Netzausbaus von den Anbietern bedient werden. Zusätzliche Kunden wirken sich im Modell also lediglich durch einen steigenden Umsatz aus, ohne dass sie in Konkurrenz um knappe Ressourcen stehen. Diese Annahme stellt den wohl größten Gegensatz zum klassischen Revenue Management dar, das sich mit der Preis- und Kapazitätssteuerung begrenzter, in der Regel verderblicher oder nach

einer gewissen Zeit verfallender Güter beschäftigt (wie z. B. Tickets für Flugverbindungen, vgl. [Klein und Steinhardt 2008], Kap. 1.2.2.1).

Einen signifikanten variablen Kostenblock im realen Mobilfunkmarkt stellen Endgerätesubventionen dar, die den Kunden häufig bei Abschluss eines Vertrags gewährt werden. Diese Kosten werden von den Anbietern aber durch höhere Grundgebühren oder Mindestumsätze wieder auf die Kunden umgelegt, sodass vereinfacht betrachtet letztendlich keine Kosten hierdurch beim Anbieter auflaufen, sondern lediglich eine Vorfinanzierung des Endgeräts stattfindet. Dieser reine Finanzierungsmechanismus sei im Modell vernachlässigt, es stellt somit einen Markt ohne Endgerätesubventionen dar.

Die angebotenen Tarife bestehen im Modell aus einer fixen Grundgebühr, variablen Nutzungsgebühren und einem Inklusivkontingent zur kostenlosen Nutzung, das ebenfalls als Preiskomponente betrachtet sei. Diese Preischarakteristika sind je Tarif als Parameter der Simulation vorgegeben, können also zwischen verschiedenen Simulationsläufen vom Anwender variiert werden. Die verwendete Tarifstruktur stellt eine klare Vereinfachung gegenüber dem realen, deutlich komplexeren Mobilfunkmarkt dar, in dem laut empirischen Studien sechs bis zwölf Preiselemente für die Entscheidung der Kunden eine Rolle spielen (vgl. [Kreye 2005], Kap. 3.4.2). Mit den in der vorliegenden Arbeit lediglich betrachteten drei Charakteristika lassen sich aber trotzdem grundsätzlich alle am Markt verbreiteten Tariftypen (vgl. Kap. 2.1.2) abbilden: (1) klassische Vertragstarife mit Grundgebühr, Minutenpreisen und ggf. Inklusivkontingent, (2) Zeittarife, die nur nach Minutenpreisen abgerechnet werden sowie (3) Pauschaltarife (Flatrates), bei denen über den fixen Betrag hinaus keine weiteren Kosten anfallen. Diese drei grundlegenden Tariftypen werden im Modell repräsentativ für die Tarifstrukturen im Markt verwendet. Jeder der Tarife hat eine definierte Mindestlaufzeit, innerhalb derer sich ein Agent nicht für einen anderen Anbieter oder Tarif entscheiden kann. Gebühren für den Abschluss oder die Kündigung eines Tarifs fallen im Modell nicht an.

Rabatte für Telefonate im lokalen Umfeld eines jeden Kunden (der sog. Nachbarschaft) oder innerhalb desselben Mobilfunknetzes werden im Modell berücksichtigt. Solche Konstrukte sind weit verbreitet und werden als Community-Rabatte bezeichnet (vgl. Kap. 2.1.4), weil die Grundgesamtheit der für den Rabatt in Frage kommenden Gegenstellen durch eine abgegrenzte Gemeinschaft von Personen gebildet wird. Diese Rabatte werden im Modell nicht direkt mit dem Preis verrechnet, sondern stellen für die Kunden einen Bonus dar, der gegen den Malus der Gesprächskosten aufgerechnet wird (mehr hierzu in Kap. 4.3.1). Dieser Ansatz umgeht relativ willkürliche Annahmen hinsichtlich des Anteils der Gespräche, für welche die Anwendung der Rabatte infrage kommt. Darüber hinaus seien keine weiteren Rabattmöglichkeiten mit einbezogen.

Die Preise der Tarife seien im Laufe der Simulation unveränderlich vorgegeben, somit schließen sich auch Konkurrenzreaktionen der Anbieter aus. Nur durch diese tatsächlich einschneidende Vereinfachung wird es in den Augen des Autors möglich, die Wirkungszusammenhänge der Netzwerkeffekte zu isolieren und besser zu verstehen. Ein komplexeres Modell mit zeitvarianten Preisen würde die Interpretation erlangter Ergebnisse unverhältnismäßig erschweren und wäre dem Forschungsinteresse somit kaum zuträglich.

Da die Anbieter im Modell keine eigenständigen Aktionen durchführen, sondern jede an sie gerichtete Nachfrage zu ihrem angebotenen Preis bedienen, kann auf eine (prinzipiell mögliche und naheliegende) explizite Modellierung der Anbieter als Agenten verzichtet werden. Die angebotenen Tarife sind folglich lediglich als Alternativenraum bei der Entscheidung der Kunden modelliert (vgl. Kap. 4.3.1).

4.3. Modellierung der Kunden

Die Kunden auf dem Mobilfunkmarkt werden im Modell durch Agenten repräsentiert, die ein heterogenes Nachfrageverhalten aufweisen und untereinander in einem sozialen Netzwerk verbunden sind. Jeder Kundenagent kann lediglich einen Tarif bei einem der Anbieter abschließen, der Gesamtmarkt ist also auf die absolute Anzahl der modellierten Kunden beschränkt. Die Entscheidung für den Abschluss eines Mobilfunkvertrags bei einem bestimmten Anbieter oder den Wechsel zu einem anderen Anbieter wird anhand einer Nutzenbewertung der zur Verfügung stehenden Alternativen vollzogen. Diese bezieht neben den anfallenden Kosten auch Qualitätsaspekte und insbesondere Netzwerkeffekte mit ein. Bei der Beschreibung des Modells wird im Folgenden insbesondere auf die Modellierung des Entscheidungsverhaltens der Agenten (Kap. 4.3.1), die Vernetzung zwischen den Agenten (Kap. 4.3.2) sowie auf deren Nachfrage- und Präferenzstruktur (Kap. 4.3.3) eingegangen.

Die Population der ABS umfasst eine zu definierende Anzahl an Agenten und ist statisch modelliert. Somit ändern sich die Charakteristika der einzelnen Agenten im Laufe der Simulation nicht. Die Agenten unterscheiden sich hinsichtlich ihrer Grundausstattung beim Start der Simulation (ein Tarif bei einem der Anbieter bzw. kein Tarif), ihrer Verbindungspartner im Netzwerk, ihrer Nachfragestruktur sowie ihrer Präferenzen. Die Agenten treten in Interaktion zueinander bei der Bewertung der zur Auswahl stehenden Tarife, indem sie die Anbieter ihrer benachbarten Agenten bei ihrer eigenen Entscheidung mit einem Nutzenbonus bewerten. Darüber hinaus existiert keine Koordination zwischen den Agenten. Das Entscheidungsverhalten der Agenten folgt dem Ziel der Nutzenmaximierung durch Auswahl der besten Alternative, wobei keine über die Nutzenbewertung hinausgehenden Faktoren und insbesondere kein Lernen aus vergangenen Perioden mit einbezogen werden. Die Kunden im vorliegenden Modell haben ein strukturell identisches Entscheidungsverhalten (im Gegensatz zum Adoptionsverhalten von Agenten in klassischen Diffusionsstudien, vgl. [Rogers 2003], dort werden verschiedene Typen unterschieden), lediglich durch individuelle Präferenzen entsteht eine Heterogenität zwischen den Agenten. Der Einfluss eines einzelnen Kundenagenten auf den Verlauf der Simulation ist also nicht vorab determiniert, sondern ergibt sich erst mit dem Ablauf der Simulation als Resultat der dynamischen Interaktion zwischen den Agenten.

Für die Modellierung sei die Annahme getroffen, dass jeder potenzielle Kunde bereits ein Mobiltelefon besitzt. Die möglicherweise notwendige Anschaffung eines Geräts würde lediglich die Einstiegsbarrieren des Kunden erhöhen, nicht aber die hier betrachtete

Positionierung der einzelnen Anbieter im Wettbewerb zueinander. Somit ließe sich dieser Effekt auch einfacher als individueller Malus im Grundnutzen der Mobiltelefonie abbilden (vgl. Kap. 4.3.1).

4.3.1. Entscheidungsmodell der Agenten

Das Entscheidungsmodell der Agenten ist die zentrale Triebfeder der ABS (vgl. Kap. 3.1.2) und bedarf deshalb einer eingehenden Betrachtung und insbesondere einer begründeten wie auch nachvollziehbaren Modellierung, die in diesem Kapitel geliefert wird. Es stellt die Basis für einen Verhaltensschritt der Agenten dar und umfasst die Alternativenauswahl, die Bewertung der Alternativen anhand von Attributen sowie die letztendliche Entscheidung für eine der Alternativen.

Empirisch beobachtetes Entscheidungsverhalten ist komplex und geprägt von einer Vielzahl unterschiedlicher (häufig nicht rationaler) Motivationen (vgl. [Kahneman und Tversky 2000]). Da aus der Literatur nur wenige konkrete empirische Erkenntnisse zum individuellen Entscheidungsverhalten von Mobilfunkkunden bei der Tarifwahl ableitbar sind (vgl. [Gerpott 2009]), kann lediglich ein vereinfachtes, normatives Modell angenommen werden. Hierzu seien strukturelle Annahmen zum Entscheidungsverhalten getroffen und diese Annahmen anhand empirischer Studien wie auch anhand einzelner Erkenntnisse aus der theoretischen Forschung begründet. Dieser Ansatz ermöglicht eine inhaltlich fundierte Annäherung an das reale System, ohne jedoch die dort wirkenden Mechanismen und Zusammenhänge im Detail zu kennen oder zu verstehen. Die vorliegende Arbeit hat also nicht den Anspruch, das „richtige“ oder „korrekte“ Entscheidungsmodell der Agenten zu konstruieren, sondern eines, welches das Verhalten der Kunden im Mobilfunkmarkt hinreichend gut beschreibt und gleichzeitig plausibel fundiert ist.

Kernelement des Entscheidungsmodells ist eine kompositionelle Nutzenbestimmung für jede der Entscheidungsalternativen durch Bewertung des Nutzens der relevanten quantitativen wie auch qualitativen Entscheidungsattribute. Das so erstellte generelle und für alle Agenten identische multiattributive Entscheidungsmodell wird durch eine agentenspezifische Gewichtung der Entscheidungsattribute sowie durch lokale Unterschiede bei der Erhebung der Entscheidungsattribute (Netzwerkeffekte) individuell ausgestaltet. Das Modell folgt dem Grundsatz eines nutzenmaximierenden Verhaltens, erklärt aber letztendlich nicht das Verhalten selbst, sondern nur den Zusammenhang zwischen den Entscheidungsattributen und der daraus resultierenden Entscheidung. Dies stellt eine Abstraktion des Entscheidungsprozesses dar, den ein Kunde im realen Mobilfunkmarkt durchläuft und dessen Ablauf nicht Gegenstand dieser Untersuchung ist. Der vorliegende Ansatz entspricht z. B. [Frels et al. 2005] oder [Zhang und Zhang 2007], steht aber im Gegensatz z. B. zu dem in [Jäger und Janssen 2003] ausführlich beschriebenen Consumat-Modell, das explizit auf einem psychologischen und sozialen Verständnis des Entscheidungsprozesses beruht.

Der Raum der diskreten Entscheidungsalternativen, die einem Agenten für die Auswahl eines Tarifs zur Verfügung stehen, wird durch die in Kapitel 4.2 beschriebenen drei Tarife für jeden der vier Anbieter gebildet. Zusätzlich kommt die Nullalternative hinzu, d. h. der Verzicht auf einen Mobilfunktarif bzw. die Kündigung eines existierenden Tarifs. Insgesamt

stehen den Agenten damit 13 Entscheidungsalternativen zur Auswahl. Die Menge der Tarife wird hierbei als jedem Agenten in der Entscheidungssituation bekannt angenommen, da für den Mobilfunkmarkt eine Vielzahl von Portalen im Internet (wie z. B. Teltarif.de²⁸) derartige Informationen kostenlos und leicht zugänglich bereitstellen.

Charakterisiert werden die Entscheidungsalternativen durch Entscheidungsattribute, die eine Bewertung bestimmter Tarifcharakteristika darstellen. Wie erstmals von [Lancaster 1966] vergleichbar beschrieben, beruht der Nutzen eines Tarifs in einer solchen Modellierung auf der Aggregation der Bewertungen der einzelnen Entscheidungsattribute. Die berücksichtigten Attribute sind hierbei für alle Tarife identisch, lediglich durch unterschiedliche konkrete Werte und unterschiedliche Gewichtungen der Attribute entstehen individuelle Unterschiede in der Nutzenbewertung zwischen verschiedenen Agenten.

Ein praxistaugliches Entscheidungsmodell sollte, wie [Lancaster 1966] zurecht bemerkt, mit der minimal notwendigen Menge an Attributen auskommen, die das gewünschte Entscheidungsverhalten hinreichend gut beschreiben. Zur Identifikation dieser relevanten Entscheidungsfaktoren für Kunden im Mobilfunkmarkt kann auf eine Vielzahl der bereits in Kapitel 2.1.3 diskutierten empirischen Studien zurückgriffen werden, die zwar nicht singulär, durchaus aber in der Gesamtbetrachtung eine gute und recht konsistente Analyse der Entscheidungssituation bieten. Daraus abgeleitet berücksichtigt das Entscheidungsmodell der vorliegenden Arbeit folgende fünf Entscheidungsattribute, für die eine hohe Relevanz bei der Entscheidung der Kunden im Mobilfunkmarkt identifiziert werden konnte:

- (A1): Nachfragebefriedigung
- (A2): Kosten der Nachfragebefriedigung
- (A3): Attraktivität des Anbieters
- (A4): Einfluss des sozialen Netzwerks
- (A5): Treue zum bisherigen Anbieter

Der Nutzen aus der Nachfragebefriedigung (A1) stellt den Gebrauchsnutzen der Mobiltelefonie dar, welcher sich unabhängig vom Nachbarschaftsnetzwerk des Agenten ergibt und unter anderem den hier nicht näher betrachteten Nutzen repräsentiert, auch mit Gegenstellen im Festnetz telefonieren zu können. Dieser sei mit null bewertet für den Fall der Nullalternative, dass ein Kunde keinen Mobilfunktarif abschließt, also eine nicht befriedigte Nachfrage oder auch keine Nachfrage aufweist. Bei Abschluss eines Tarifs hingegen sei dieser Nutzen mit der Anzahl der nachgefragten Mobilfunkminuten bewertet, der Nutzen steigt also linear mit der nachgefragten Menge. Ein Wenigtelefonierer zieht somit proportional weniger Nutzen aus der Befriedigung seiner Nachfrage als ein Vieltelefonierer. Die Kosten der Nachfragebefriedigung (A2) stellen einen Disnutzen (d. h. einen negativen Nutzen) dar und werden mit den in dem gewählten Tarif für die individuelle Nachfrage (vgl. Kap. 4.3.3) anfallenden Kosten bewertet, die sich aus der Grundgebühr und variablen

²⁸ <http://www.teltarif.de/>, abgerufen am 21. Februar 2010.

Nutzungsgebühren unter Verrechnung der kostenlosen Inklusivnutzung zusammensetzen. Für die Nullalternative werden die Kosten mit null bewertet.

Die Attraktivität (A3) ist ein je Anbieter zu definierender, statisch vorgegebener Faktor, der sowohl anbieterbezogene Aspekte wie die Netzqualität, den Kundenservice oder die Vertriebsintensität als auch produktportfoliobezogene Aspekte wie die Produktwertigkeit mit einbezieht. Für die Nullalternative ist dieser Wert null.

Der Einfluss des sozialen Netzwerks (A4) ergibt sich wie in Kapitel 2.1.4 ausführlich beschrieben aus verschiedenen Faktoren finanzieller wie auch psychologischer Natur sowie aus individuellen praktischen Erwägungen. Diese Einflussfaktoren lassen sich nur schwer voneinander trennen und separat bewerten, weshalb für diesen Faktor ein gesamthafter abstrakter Nutzen abgeleitet wird. [Schade et al. 2009] zeigen zwar, dass man einen solchen Netzwerknutzen auch direkt monetär bewerten kann, dessen Wert hängt dann aber entscheidend vom Anteil der netzinternen Gespräche ab, für den die Autoren nur grobe Annahmen treffen können. Auch [Janssen und Jager 2002] modellieren eine Präferenz für in der Nachbarschaft verbreitete Produkte, allerdings resultiert diese nicht aus reinen Nutzen-erwägungen, sondern aus komplexeren sozialen Bedürfnissen der Kunden. Im vorliegenden Modell hingegen wird der Nutzenwert durch den Anteil der Nachbarn (bezogen auf die gesamte Anzahl der Nachbarn) gebildet, die beim gleichen Anbieter einen (beliebigen) Tarif abgeschlossen haben. Dieser Nutzenwert ist entsprechend minimal null, wenn keine Nachbarn beim selben Anbieter einen Tarif haben. Maximal entspricht der Nutzenwert der Zahl Eins, falls alle Nachbarn bei diesem Anbieter einen Tarif haben. Der Nutzen steht im vorliegenden Modell somit in linearem Zusammenhang zum Anteil der relevanten individuellen Nachbarschaft, was sich durch die ebenfalls linear wachsende mögliche Kostenersparnis aufgrund von Community-Rabatten begründen lässt. In [Liehr 2005] (Kap. B.3.5) werden noch weitere, alternativ mögliche funktionale Zusammenhänge für den Netzwerknutzen diskutiert.

Die Treue zum bisherigen Anbieter (A5) ist ein binärer Faktor, der die Wechselwilligkeit der Kunden begrenzt. Dieses Attribut trägt den Wert eins für alle Tarife des bisherigen Anbieters und null für alle anderen Tarife. Hierbei wird davon ausgegangen, dass hinter der Nullalternative ebenfalls ein angenommener Nullanbieter steht, also auch hier die Beibehaltung der Situation ohne Tarif einen positiven Nutzen hervorruft. Dieses Entscheidungsattribut bildet die Tatsache im Markt ab, dass Anbieter ihren Kunden den Wechsel zu einem anderen Anbieter durch Mindestlaufzeiten oder Kosten für die Rufnummernmitnahme erschweren, während ein Wechsel in einen anderen Tarif beim selben Anbieter in der Regel problemlos möglich ist.

Die Bewertung der Entscheidungsattribute (A1) bis (A3) ist statisch und kann vorab für jeden Agenten berechnet und zwischengespeichert werden. Die Werte für (A4) und (A5) ergeben sich hingegen erst dynamisch im Verlauf der Simulation, wobei dies beim Einfluss des sozialen Netzwerks durch dynamische Netzwerkeffekte ausgelöst wird, während sich bei der Treue zum bisherigen Anbieter die Pfadabhängigkeit der Simulation auswirkt. Diese dynamischen Attribute begründen die hohen Rechenanforderungen einer solchen ABS, da die Erhebung und Berechnung für jede Periode und darin für jeden Agenten separat verarbeitet werden muss.

Vergleichbare Entscheidungsmodelle bezogen auf den Mobilfunkmarkt finden sich vereinzelt in der Literatur. [Doganoglu und Grzybowski 2007] berücksichtigen als Entscheidungsattribute den Preis, den Nutzen aus Netzwerkeffekten sowie den Nutzen des jeweiligen Anbieters. Netzwerkeffekte sind auch hier als abstrakter Nutzen formuliert, der linear von der Größe des Gesamtnetzwerks abhängt. [Iyengar et al. 2007] beziehen die Nachfragebefriedigung auf Basis der erwarteten Nutzungsintensität sowie die erwartete Qualität des Mobilfunkservice mit ein. Die bereits genannten [Schade et al. 2009] berücksichtigen die durch Mobilfunknutzung entstehenden Kosten, reduziert um die Ersparnis aus netzwerkbezogenen Rabatten, sowie Kosten für einen möglichen Anbieterwechsel.

Im Modell wird ein probabilistisches Entscheidungsverhalten (vgl. [Luce 1959], S. 2) der Kunden im Mobilfunkmarkt unterstellt. Dies bedeutet, dass diese Akteure eine Entscheidung auf der Grundlage sowohl ökonomisch rationaler, berechenbarer Faktoren als auch zufälliger Einflüsse treffen. Um ein solches Verhalten in einem Entscheidungsmodell abbilden zu können, bedarf es zum einen einer Zusammenführung der diskutierten einzelnen Attributnutzen, zum anderen aber auch der Modellierung stochastischer Einflüsse. Beide Anforderungen lassen sich mit einer additiven teilstochastischen Nutzenfunktion adressieren, eine Modellierung, die sowohl in der mathematischen Psychologie (vgl. [Homburg und Krohmer 2009], Kap. 2.3.2.1) als auch in Discrete-Choice-Modellen (vgl. [Gönsch et al. 2008]) ihre Verwendung findet. In der Forschung zur ABS ist dieser Ansatz ebenfalls verbreitet, beispielsweise nutzen [Rauh et al. 2007] ein solches Modell für die Simulation der Entscheidungen von Kunden im Lebensmitteleinzelhandel. Die Popularität dieser Modellierung resultiert aus der Tatsache, dass nur geringe Anforderungen an die verwendeten Attributbewertungen zu stellen sind: Diese müssen lediglich einen monoton steigenden Nutzen haben, nicht gegenseitig voneinander abhängen, kompensatorisch wirken können (weniger Nutzen bei einem Attribut kann durch mehr Nutzen bei einem anderen Attribut ausgeglichen werden, vgl. [Späth 1995], S. 122) und keine zusätzlichen Einschränkungen (z. B. KO-Kriterien) aufweisen. Bei der Zusammenführung der Attributbewertungen wird in diesem Modell mangels anderweitiger Erkenntnisse ein linearer Zusammenhang unterstellt. Wäre ein nichtlinearer Zusammenhang bekannt, so könnte dieser prinzipiell durch eine geeignete Transformation oder Verknüpfung von Attributwerten abgebildet werden.

Formal werden also in der Nutzenfunktion die Teilnutzen U^A der einzelnen Attribute $A1 \dots A5$ mittels Gewichten β^A zueinander in Relation gesetzt, aufsummiert und um einen stochastischen Summanden ε ergänzt. Damit lässt sich der Nutzen V_j der Entscheidungsalternative j wie folgt berechnen:

$$V_j = \beta^{A1} \cdot U_j^{A1} + \dots + \beta^{A5} \cdot U_j^{A5} + \varepsilon$$

Diese Berechnung erfolgt individuell für jeden Agenten immer dann im Verlauf der Simulation, wenn er eine Entscheidung zu treffen hat.

Auf eine in vielen vergleichbaren Modellierungen verwendete alternativenspezifische Nutzenkonstante (vgl. [Gönsch et al. 2008]) sei an dieser Stelle verzichtet. Diese könnte aber je nach Anwendungsfall eine sinnvolle Erweiterung des Nutzenmodells darstellen, sofern

spezifische Aspekte eines bestimmten Tariftyps bei der Entscheidung relevant sind, die sich aber nicht in den übrigen modellierten Entscheidungsattributen ausdrücken.

Den Gewichten β^A kommt im Modell eine spezielle Bedeutung zu, sie sorgen nicht nur für eine Normierung der ihrem Höhenniveau nach potenziell sehr unterschiedlichen Teilnutzen, sondern können auch je Agent individuell gestaltet werden. So lassen sich Agenten modellieren, die sich in ihren Präferenzen hinsichtlich der einbezogenen Entscheidungsattribute unterscheiden. Diese Möglichkeit wird genutzt, indem in Kapitel 4.3.3 verschiedene Segmente von Mobilfunknutzern identifiziert und diese mit einem auf deren typische Präferenzen zugeschnittenen Profil an Gewichten ausgestattet werden. Solche Gewichte lassen sich auch direkt auf Basis empirischer Daten aus Kundenbefragungen oder Laborexperimenten schätzen (vgl. [Gönsch et al. 2008]), wie z. B. [Skiera 1999] (Kap. 5) und [Frels et al. 2006] zeigen. Die Mobilfunkanbieter selbst verfügen zwar über eine umfangreiche Datenbasis zum Auswahlverhalten innerhalb ihrer eigenen Tarifstruktur, haben aber keine Daten darüber, welche Entscheidungen die Kunden der Konkurrenzanbieter genau treffen. Für die betrachtete Problemstellung käme also eine Schätzung der Gewichte für die Entscheidungsmodellierung auf Basis vorhandener Daten eines Mobilfunkanbieters in Kombination mit dedizierten Laborexperimenten infrage. Alternativ könnten die Gewichte anhand einer beobachteten Marktentwicklung so kalibriert werden, dass die Simulation diese empirische Marktentwicklung möglichst präzise nachzeichnet. Beides würde jedoch den Rahmen der vorliegenden Arbeit sprengen, weswegen lediglich die angenommenen Präferenzen repräsentativer Kundengruppen berücksichtigt werden, die sich aus verschiedenen bereits zitierten empirischen Studien indikativ herleiten.

Studien zum Tarifwahlverhalten im Mobilfunkmarkt zeigen, dass ein signifikanter Anteil der Kunden einen Tarif wählt, der nicht optimal bezogen auf ihr Nutzungsverhalten ist (siehe z. B. [Gerpott 2009]). Mobilfunkanbieter forcieren diese suboptimale Entscheidungsfindung durch die Bildung eines intransparenten Marktes mit einer kaum zu überblickenden Vielzahl unterschiedlicher Tarife und wählbarer Zusatzoptionen (vgl. [Rams 2001]), da sich jede für den Kunden hierbei nicht optimale Entscheidung normalerweise direkt in einem höheren Umsatz für den Anbieter niederschlägt. Das nicht vollständig ökonomisch rationale Entscheidungsverhalten wird mit dem stochastischen Summanden ε als sogenanntem Störterm dargestellt, der sowohl erratisches Entscheidungsverhalten, mögliche Unsicherheiten in der Bewertung der Entscheidungsattribute als auch nicht beobachtete bzw. nicht einbezogene Entscheidungsattribute (wie z. B. Flexibilität oder Bequemlichkeit) abbildet. Für den Störterm sei in diesem Modell beispielhaft die auch in Logit-Modellen (vgl. [Gönsch et al. 2008]) verwendete Gumbel-Verteilung mit zu definierenden Parametern unterstellt. Diese Verteilung hat zwar einen von null abweichenden Erwartungswert, bei der Verwendung im Entscheidungsmodell hat das jedoch keine praktische Relevanz, da dies lediglich in einer für alle bewerteten Alternativen identischen Mittelwertverschiebung des Erwartungswertes des Nutzens resultiert.

Sind für alle Entscheidungsalternativen j deren Nutzen V_j berechnet, so erfolgt die Entscheidung des Agenten im Modell nach der einfachen Regel, die Alternative mit dem

größten Nutzenwert auszuwählen. Alternativ findet sich in der Literatur auch das Konzept, den Störterm ε bei der Nutzenbewertung wegzulassen. Stattdessen kann der Agent dann proportional anhand der resultierenden deterministischen Nutzenwerte V_j zwischen den Alternativen stochastisch entscheiden. Im Erwartungswert hätte Alternative j so eine Auswahlwahrscheinlichkeit von $V_j / \sum_j V_j$.

4.3.2. Netzwerk der sozialen Interaktion

Die Modellierung sozialer Netzwerke ist ein Forschungsfeld, das die Wissenschaft seit Jahren beschäftigt (vgl. [Newman 2003], Abs. 2.1) und das inzwischen umfassend aufgearbeitet wurde (vgl. z. B. [Jackson 2008]). Typischer Forschungsgegenstand ist hierbei die Fragestellung, wie sich empirische Netzwerke (z. B. eine Nachbarschaft, ein Freundeskreis oder auch Kontakte in sozialen Online-Netzwerken) modelltechnisch operationalisieren lassen, um speziell die über die Verbindungen des Netzwerks abgewickelte Interaktion der sozialen Individuen geeignet abbilden zu können. Von Interesse ist hierbei, welche relevanten Eigenschaften das betrachtete empirische Netzwerk besitzt (für eine breite Übersicht siehe [Newman 2003], Abs. 3) und wie sich diese Eigenschaften in einem Modell generalisieren lassen.

In einem Netzwerkmodell wird ein Agent durch einen Knoten abgebildet und die Nachbarschaft dieses Agenten ist definiert durch die Menge der Netzwerkknoten, die mit seinem Knoten durch eine Kante verbunden sind (vgl. auch [Scott 2000], S. 67). Neben einfachen Modellen wie einem rein zufällig geknüpften Netzwerk oder einem Ringnetzwerk hat insbesondere die Einführung von „Small-world“-Netzwerkmodellen (vgl. [Watts und Strogatz 1998]) und skalenfreien Netzwerkmodellen mit bevorzugten Verbindungspartnern (vgl. [Barabási und Albert 1999]) eine Flut von Arbeiten ausgelöst, die sich mit der Konstruktion und den Eigenschaften dieser Netzwerkmodelle auseinandersetzen (vgl. [Newman 2003]). Diesen beiden grundlegenden Modellen ist gemein, dass sie einem einzelnen Aspekt sozialer Netzwerke eine hohe Aufmerksamkeit widmen, während andere Aspekte ganz oder zumindest teilweise vernachlässigt werden: „Small-world“-Netzwerke haben ihre Stärken bei der Abbildung einer realitätsnah kurzen Pfadlänge und einer typischen Clusterbildung, während skalenfreie Netzwerke vor allem das Charakteristikum berücksichtigen, dass Personen mit einer hohen Anzahl Verbindungspartner auch mit einer größeren Wahrscheinlichkeit neue Verbindungen knüpfen, diesen Zusammenhang also inhärent verstärken.

Wie [Hamill und Gilbert 2009] ausführlich herausarbeiten, wurden diese Netzwerkmodelle aber nicht entwickelt, um systematisch die gesamte Breite der Charakteristika sozialer Netzwerke zu adressieren und somit eine konsistente Realitätsnähe zu erreichen. Genau dies ist aber die Anforderung einer ABS, bei der das Netzwerk in der Regel nicht der eigentliche Forschungsgegenstand ist, sondern wie auch z. B. das Entscheidungsmodell lediglich einen Teilaspekt darstellt, für den eine möglichst gut geeignete Modellierung gesucht wird. [Janssen und Jager 2003] weisen außerdem darauf hin, dass es kaum allgemeingültige Erkenntnisse darüber gibt, wie man für einen konkreten Markt das passende Netzwerkmodell herleiten könnte. In der vorliegenden Arbeit wird deshalb kein intensiver Vergleich der in der Literatur gebräuchlichen Netzwerkmodelle durchgeführt und darauf basierend eines ausgewählt, sondern es sei das in [Hamill und Gilbert 2009] vorgeschlagene erweiterte „2-

reaches“-Modell verwendet. Dieses Modell adressiert trotz seiner Einfachheit eine breite Masse relevanter Charakteristika sozialer Netzwerke: (1) eine geringe Dichte der Verbindungen zwischen Knoten, (2) eine begrenzte Größe der individuellen Nachbarschaften, (3) eine variierende Verteilung der Größe der individuellen Nachbarschaften, die (4) insbesondere ein „fat tail“ aufweist, (5) eine positive Korrelation zwischen der Anzahl der Verbindungspartner benachbarter Knoten, (6) eine ausgeprägte Clusterbildung, (7) eine deutliche Abgrenzung von Untergruppen von Knoten sowie (8) eine kurze Pfadlänge zwischen den Knoten. Zentrales Konzept dieser Modellierung ist der räumliche Nachbarschaftsradius („social reach“), der für jeden Agenten in dem flachen zweidimensionalen Umweltkoordinatensystem festlegt, welche anderen Agenten seine Nachbarn sind, zu denen eine direkte Verbindung angenommen wird. Im erweiterten „2-reaches“-Modell werden die Agenten zusätzlich in zwei Gruppen mit unterschiedlich großen Nachbarschaftsradien aufgeteilt, wobei weiterhin zwei Agenten nur dann eine Verbindung aufweisen, wenn beide sich gegenseitig als Nachbarn betrachten. Netzwerkverbindungen werden hierbei nur symmetrisch und somit ungerichtet konstruiert, eine Annahme, die von [Birke und Swann 2005] auch empirisch näherungsweise gestützt wird. Von Vorteil für die Verwendung dieses Netzwerkmodells innerhalb einer ABS ist, dass sich bei der Konstruktion des Netzwerks nicht nur die Verbindungen der Agenten untereinander ergeben, sondern auch deren räumliche Positionierung, was die spätere Visualisierung der Simulation vereinfacht.

Zur Erstellung eines solchen Netzwerks sind verschiedene Parameter zu definieren: die Anzahl $A \in \mathbb{N}$ der Agenten; die Kantenlänge $l \in \mathbb{R}$ der quadratischen Umwelt; der einfache Nachbarschaftsradius $r \in \mathbb{R} < l$; der erweiterte Nachbarschaftsradius $r^* \in \mathbb{R} < l$ sowie der Anteil der Agenten mit erweitertem Nachbarschaftsradius $\varphi \in]0; 1[$. Die Konstruktion funktioniert dann recht simpel: Für jeden Agenten wird zufällig eine Position in der Umwelt gewählt sowie anhand der Wahrscheinlichkeit φ zufällig bestimmt, ob dieser einen erweiterten Nachbarschaftsradius besitzt. Die Agenten werden ohne bestimmte Reihenfolge in eine gemeinsame Liste gestellt, von der iterativ jeweils das erste Element herausgenommen wird. Für diesen Agenten wird für jeden der in der Liste verbliebenen Agenten überprüft, ob der euklidische Abstand zwischen beiden kleiner ist als der einfache Nachbarschaftsradius r , bzw. falls beide Agenten einen erweiterten Nachbarschaftsradius besitzen, ob der Abstand kleiner ist als r^* . In beiden Fällen wird eine Verbindung zwischen beiden Agenten registriert. Die Konstruktion des Netzwerks ist abgeschlossen, sobald die Liste der noch nicht betrachteten Agenten leer ist.

Freilich zeigen andere agentenbasierte Simulationsstudien wie beispielsweise [Wendt et al. 2000] einen entscheidenden Einfluss der Netzwerkstruktur auf die Diffusion von Produkten im Markt für Informations- und Kommunikationstechnologie. Von vielen vergleichbaren Studien wie z. B. [Valente 1995] wird das auch grundsätzlich bestätigt. Die Implikationen hieraus für die vorliegende Arbeit sind aber begrenzt. Diese Art der Diffusionsstudien betrachtet in der Regel die Erschließung leerer Märkte, außerdem ist es meist auch erklärtes Ziel der jeweiligen Studie, durch die Netzwerkstruktur bedingte Unterschiede herauszuarbeiten. Es lässt sich hieraus aber zumindest ableiten, dass die Struktur des im Modell verwendeten Netzwerks ein Faktor ist, dessen Einfluss auf die konkret betrachtete Problemstellung im Rahmen einer abschließenden Sensitivitätsanalyse untersucht werden kann.

4.3.3. Nachfrage- und Präferenzstruktur der Agenten

Neben der Struktur der Nachbarschaft sind die Agenten im Modell mit weiteren individuellen Charakteristika ausgestattet. Zu diesen zählen die Gewichtung der Entscheidungsattribute zur Abbildung von Präferenzen, die individuelle Nachfrage sowie die Grundausstattung mit einem Tarif und dessen Restlaufzeit.

Typischerweise erfolgt auf dem Mobilfunkmarkt eine Einteilung der Kunden in Privat- und Geschäftskunden. Zwischen diesen beiden Gruppen wird eine abweichende Nachfrage- und Präferenzstruktur sowie ein signifikant unterschiedlicher Entscheidungsprozess unterstellt. Tendenziell ist die Höhe der Nachfrage von Geschäftskunden eher vorgegeben und bestimmt den zwischen dem nachfragenden Unternehmen und dem Mobilfunkanbieter verhandelbaren Preis. Umgekehrt haben Privatkunden wenig Einfluss auf den Preis der Mobilfunkleistung, können ihre Nachfrage aber in der Regel eher den jeweiligen Kosten anpassen, z. B. kürzere Telefongespräche führen.

In der Literatur finden sich kaum verwertbare Vergleiche des Tarifwahlverhaltens von Privat- und Geschäftskunden (vgl. [Stingel 2008], S. 188). Geschäftskunden werden deshalb im Modell lediglich anhand ihres Nutzungs- und Präferenzverhaltens von Privatkunden unterschieden. Somit bleibt unberücksichtigt, dass Geschäftskunden oftmals nicht unmittelbar selbst über ihren Mobilfunkanbieter und -tarif entscheiden, sondern diese Entscheidung mittelbar durch eine Einkaufsabteilung aggregiert vorgenommen wird (vgl. [Stingel 2008], Kap 3.1.2). Deren relevante Entscheidungsattribute weichen hierbei allerdings nicht signifikant von denen von Privatkunden ab (vgl. [Stingel 2008], S. 52) und unterscheiden sich lediglich bei der Gewichtung der Attribute. Diese abweichende Gewichtung wird in der vorliegenden Modellierung in Form spezieller Kundensegmente berücksichtigt. Die Modellierung von Privat- wie auch Geschäftskunden als individuelle Entscheider wird zudem unterstützt von empirischen Umfrageergebnissen aus [Focus Verlag/TNS Infratest 2009] (S. 60), wonach 94 % der repräsentativ ausgewählten Umfrageteilnehmer ihr Mobiltelefon selbst aussuchen, sowie von [Chip Xonio Online 2007], wonach sogar 97 % über den Kauf eines neuen Mobiltelefons selbstständig entscheiden. Der Schluss liegt also nahe, dass dieser Sachverhalt beim zugehörigen Tarif zumindest tendenziell ähnlich ausgeprägt ist.

Da wie bereits ausgeführt keine hinreichend belastbaren und übergreifend gültigen Daten zu den individuellen Präferenzen von Kunden im Mobilfunkmarkt vorliegen, seien zu diesem Zweck fünf typische und gut voneinander abgrenzbare Segmente von Kunden mit deren jeweils als charakteristisch angenommenen Präferenz- und Nachfragestrukturen entworfen:

- I. geschäftliche, nicht-preissensitive Vieltelefonierer,
- II. geschäftliche, preissensitive Vieltelefonierer,
- III. private Vieltelefonierer,
- IV. private Durchschnittstelefonierer und
- V. private Wenigtelefonierer.

Zum Segment I zählen z. B. Unternehmensberater, die viel unterwegs sind und deshalb auf Mobiltelefonie angewiesen sind. Bei der Auswahl eines Tarifs achten diese Kunden eher auf

Attraktivitätsaspekte als auf den Preis. Das Segment II erfasst Außendienstmitarbeiter wie z. B. Versicherungsvertreter oder Immobilienmakler, die zwar ebenfalls unterwegs in größerem Umfang telefonieren, bei der Auswahl eines Tarifs aber deutlich preissensitiver agieren. Für beide Segmente gilt, dass sich die Kunden eher homogen zu ihren Kollegen in der Nachbarschaft entscheiden, um unnötige Komplexität beim Management der Vertragsbeziehung innerhalb eines Unternehmens zu vermeiden. Das Segment III umfasst Privatleute, die viel telefonieren und für die das Mobiltelefon häufig das alleinige Kommunikationsgerät darstellt. Da diese Personen einen großen und vor allem auch wechselnden Kreis an Gegenpartnern erwarten können, spielen Netzwerkeffekte hier eher eine untergeordnete Rolle. Vielmehr besteht ein zentrales Interesse an der kostengünstigen Befriedigung ihrer hohen Nachfrage. Das Segment IV besteht aus Privatleuten mit durchschnittlichem Gesprächsvolumen, die ihre Entscheidungen sehr stark an ihrem sozialen Umfeld ausrichten, genau wie auch die Wenigtelefonierer aus Segment V. Die beiden letzten Segmente sind preissensitiv und würden im Zweifel auch ohne einen Mobilfunktarif auskommen, wobei für das letzte Segment insbesondere die Attraktivität eines Anbieters auch keine entscheidende Rolle mehr spielt.

Im Modell sind diese Kundensegmente jeweils durch spezifische Wertebelegungen der Gewichte β^A und spezifische Nachfragehöhen zu definieren. Für jeden Agenten wird seine individuelle Nachfrage zu Beginn der Simulation aus der Nachfrage des ihm zugeordneten Segments gebildet, die zur geeigneten Randomisierung (vgl. [Doganoglu und Grzybowski 2007]) mit einer aus dem gleichverteilten Intervall $[0; 2]$ gezogenen Zufallszahl multipliziert wird. Die Vorgabe eines statischen Nachfragewerts über den gesamten Simulationsverlauf folgt dem Leitgedanken, dass ein Kunde einen Grundbedarf der Mobilfunkkommunikation hat. Darüber hinausgehende, preisinduzierte Nachfrage sei nicht berücksichtigt, eine solche preisabhängige Nachfragemodellierung wäre aber nach Einschätzung des Autors eine interessante Erweiterung des Modells.

Bei der Verteilung der Kundenagenten auf die Segmente sei angenommen, dass alle fünf Segmente gleich groß sind. Dementsprechend wird jeder Agent zu Beginn der Simulation zufällig einem der Segmente zugeordnet. Eine empirisch besser begründete Aufteilung der Segmente ist für den deutschen Mobilfunkmarkt wie [Stingel 2008] (S. 5) bemerkt nach Datenlage kaum möglich, da selbst die umfangreichen Erhebungen der Bundesnetzagentur eine solche Unterscheidung nicht zulassen.

Die anfängliche Ausstattung der Kundenagenten mit Tarifen ist schließlich über eine prozentuale Verteilung als Parameter zu definieren, aus der sich jeder Agent zufällig seine Tarifausstattung bei der Modellinitialisierung zieht.

4.4. Simulationsablauf und -visualisierung

Beim Start der Simulation wird zuerst die Initialisierung durchlaufen. Hierbei wird wie in Kapitel 4.3.2 beschrieben das statische Netzwerk der Verbindungen der Agenten untereinander konstruiert sowie wie in Kapitel 4.3.3 beschrieben die Zuordnung der Agenten zu den Kundensegmenten, die Bestimmung der individuellen Nachfrage, der initialen Tarifausstattung und der Restlaufzeit vorgenommen.

Die Aktionen der einzelnen Agenten werden ohne festgelegte Ablaufreihenfolge zufällig von der Simulationsumgebung ausgelöst. Es ist lediglich vorgegeben, dass jeder Agent in jeder Periode einmal zum Zuge kommt. Sobald ein Agent in Aktion tritt und sich zu dem Zeitpunkt nicht mehr innerhalb seiner Mindestvertragslaufzeit befindet, bieten sich ihm als Entscheidungsalternativen die jeweils drei verschiedenen Tarife bei den vier Anbietern sowie die Nullalternative, d. h. der Abschluss keines Tarifs – ebenfalls mit einer angenommenen Bindung der Dauer einer Mindestvertragslaufzeit. Jede dieser insgesamt 13 Entscheidungsalternativen wird von dem Agenten anhand der in Kapitel 4.3.1 beschriebenen Nutzenfunktion bewertet. Die Alternative mit dem größten teilstochastischen Nutzen wird schließlich ausgewählt. Falls diese Entscheidung von dem bis dahin abgeschlossenen Tarif abweicht, wird dem Agenten der neue Tarif (bzw. für die Nullalternative kein Tarif) zugewiesen. Da sich durch die Entscheidung für einen neuen Tarif der Simulationszustand für die übrigen Agenten ändert, müssen daraufhin die Statistiken der Nachbarn des Agenten hinsichtlich deren Nachbarschaft aktualisiert werden, die als Grundlage für deren Bewertung der netzwerkbezogenen Entscheidungsattribute dienen. Diese dezentrale Aktualisierung der Zustandsstatistiken hat den entscheidenden Vorteil, dass nicht bei jeder Aktion eines Agenten dessen gesamte Nachbarschaft abgefragt, sondern eine Aktualisierung nur für den vergleichsweise seltenen Fall vorgenommen werden muss, dass sich der Tarif eines Nachbarn geändert hat.

Aus dem Ablauf der Simulation lässt sich ein repräsentativer Zielfunktionswert berechnen, der den Simulationsverlauf aus einem bestimmten Blickwinkel quantitativ charakterisiert und für die später betrachtete Optimierung der Simulation herangezogen werden kann. Im Rahmen der vorliegenden Arbeit werden insbesondere die Ziele der Mobilfunkanbieter zur Preisoptimierung, wie in Kapitel 2.3 beschrieben, betrachtet. Typische Zielkriterien sind demnach z. B. der über mehrere Perioden kumulierte Umsatz oder Marktanteil eines Anbieters.

Häufig lässt sich in einer solch komplexen betriebswirtschaftlichen Entscheidungssituation jedoch kein isoliertes Ziel definieren, sondern lediglich ein (ggf. priorisierter) Kanon an Zielgrößen. Wirken die Ziele nicht gegenseitig ausschließend, so kann man diese aber recht einfach über eine gewichtete Zielfunktion aggregieren. Sind die verschiedenen Zielgrößen jedoch antonym, scheitern solche Ansätze, die auf einer Zusammenführung der Zielgrößen beruhen. In einem solchen Fall bietet sich die Verwendung klassischer Ansätze der Mehrzieloptimierung an, wie z. B. [Narzisi et al. 2006] zeigen.

Geschieht die Bewertung der verschiedenen Entscheidungsalternativen unter Unsicherheit, kann es zweckdienlich sein, neben dem Stichproben-Mittelwert der Bewertung auch die Streuung der Bewertungen in das Zielkriterium mit einzubeziehen. So kann eine Preisstruktur mit niedriger Varianz einer vergleichbaren anderen Preisstruktur mit hoher Varianz vorgezogen werden. Beispielsweise stellen [Klein und Scholl 2004] (Kap. 8.2.2.2) hierfür das (μ, σ) -Kriterium vor, bei dem der Erwartungswert einer Lösung um einen gewichteten Anteil der Varianz reduziert wird.

Das vorgestellte Modell wurde wie in Kapitel 4.6 näher beschrieben in AnyLogic prototypisch implementiert, die folgenden Abbildungen stammen hieraus. In dieser Simulationsumgebung lässt sich der Ablauf der Simulation anhand einer grafischen Oberfläche verfolgen (vgl. Abbildung 21 ff.), in der das Netzwerk der Agenten sowie aktuelle Statistiken zur Simulation dargestellt werden.

Die gezeigte Form der Visualisierung ist insbesondere dazu ausgelegt, den Ablauf der Simulation für den Anwender qualitativ wie auch quantitativ greifbar zu machen und so eine Validierung durch direkte Inaugenscheinnahme einzelner Aspekte und einen Vergleich mit bekannten Zusammenhängen aus dem realen System zu ermöglichen.




Abbildung 21: Grafische Oberfläche der Simulation

Quelle: eigene Darstellung

Von zentraler Bedeutung für die Analyse der Simulation sind die Anzahl der Agenten in den verschiedenen Tarifen, die hieraus resultierenden Marktanteile sowie die durch die Anbieter generierten Umsätze. Diese Größen lassen sich jederzeit nach Tarifen aufgeschlüsselt im Statusbereich der Simulation (vgl. Abbildung 22) sowohl grafisch als auch numerisch einsehen. Auch die Anzahl der bereits abgelaufenen Simulationsperioden wird dort angezeigt.

Um die Entscheidungssituation eines Agenten detailliert untersuchen zu können, werden für den selektierten Agenten außerdem die zuletzt ermittelten Nutzenbewertungen der einzelnen Entscheidungsalternativen dargestellt (vgl. Abbildung 24 links). Für einen ausgewählten Tarif (türkis dargestellt) lassen sich außerdem die Bewertungen der einzelnen Entscheidungsattribute im Detail betrachten (vgl. Abbildung 24 rechts).




Abbildung 24: Nutzenbewertungen der Entscheidungsalternativen

Quelle: eigene Darstellung

Nach dem Ablauf der Simulation kann ausgewertet werden, welche Konsequenzen die als Parameter der Simulation vorgegebenen Preise der Mobilfunkanbieter z. B. für die Marktdurchdringung der jeweiligen Tarife hatten. Durch eine Modifikation der Preise und nochmalige Simulation lässt sich außerdem die Sensitivität des Systems analysieren, oder es können bei mehrmaliger Simulation iterativ die Preise für einen Anbieter optimiert werden. Letzterer Ansatz wird im weiteren Verlauf dieser Arbeit im Detail diskutiert, mögliche Umsetzungsoptionen werden aufgezeigt (vgl. Kap. 6) und beispielhafte Preisoptimierungen durchgeführt (vgl. Kap. 8).

4.5. Prototypische Parametrisierung des Simulationsmodells

Im weiteren Verlauf dieser Arbeit wird das vorgestellte Simulationsmodell als ein praxisnaher Anwendungsfall für die simulationsbasierte Optimierung einer agentenbasierten Simulation verwendet. Hierzu sei die bisher bewusst ausgesparte Parametrisierung des Simulationsmodells an dieser Stelle in Form eines exemplarischen Prototyps mit aufeinander abgestimmten Parameterwerten nachgeholt. Die vorgestellten Parameter lehnen sich soweit möglich an empirische Daten des zugrunde liegenden deutschen Mobilfunkmarktes an bzw. orientieren sich an bewährten Ansätzen vergleichbarer Simulationsstudien aus der einschlägigen wissenschaftlichen Literatur.

Für die Zeitsteuerung der Simulation werden 36 Modellperioden verwendet. Diese sollen 36 Monaten im realen System entsprechen und stellen somit einen mittelfristigen Planungshorizont dar. Die Mindestvertragslaufzeit eines Agenten wird im Modell pauschal mit zwölf Monaten nach Abschluss eines Tarifs angenommen.

Die Anzahl der Kunden, die als Agenten im Modell repräsentiert sind, sei mit 1.000 auf einen Wert festgelegt, der sich in experimentellen Sensitivitätsanalysen als groß genug erwiesen hat, um stabile Aussagen über die Simulation abzuleiten. Dies stellt jedoch eine deutliche Abstraktion vom realen Mobilfunkmarkt dar, der in Deutschland viele Millionen Kunden umfasst (vgl. Kap. 2.1.1). Eine Vergrößerung der Agentenpopulation würde nach den Erkenntnissen aus Beispielerperimenten lediglich in einer quadratisch steigenden Rechenzeit für die Abarbeitung der Simulation resultieren, jedoch nicht in abweichenden abgeleiteten Erkenntnissen. Von Vorteil ist auch, dass bei dieser begrenzten Anzahl an Agenten eine Visualisierung der einzelnen Agenten mit ihrem Nachbarschaftsnetzwerk noch möglich ist (vgl. Kap. 4.4). Dies erhöht grundsätzlich die Transparenz der Simulation. In der Literatur werden in vergleichbaren agentenbasierten Simulationsstudien ähnliche Größen der Agentenpopulation genannt: [Frels et al. 2006] verwenden ohne nähere Diskussion 600 Agenten als Konsumenten in ihrem Marktmodell, ähnlich wie [Terano 2007] (Abs. 5.3) 1.000 Agenten zur Simulation von Investoren auf einem Finanzmarkt einsetzt und [Strube et al. 2007] ebenfalls 1.000 Agenten als Kunden auf dem Videokonsolenmarkt simulieren. [Wendt et al. 2000] verwenden 1.000 Agenten zur Simulation der Diffusion von Produkten auf Märkten der Informations- und Kommunikationstechnologie, wobei die Autoren in einer Sensitivitätsanalyse keinen signifikanten Unterschied auch bei anderen Größen der Agentenpopulation finden, ebenso wie [Rahmandad und Sterman 2008] (S. 1002 ff.) 200 Agenten verwenden und keine signifikante Veränderung der Simulation zwischen 50 und 800 Agenten feststellen. [Shi und Brooks 2007] schließlich verwenden 500 Agenten mit der Begründung, dass diese Zahl der Größe einer kleinen Gemeinschaft entspricht. [Kiesling et al. 2009] weichen mit 100.000 Agenten als simulierten Kunden auf dem österreichischen Markt für Biosprit hingegen deutlich von dieser Größenordnung ab, jedoch ohne eine modelltechnische Begründung für diesen vergleichsweise hohen Simulationsaufwand zu liefern.

Zur Konstruktion des Netzwerks der Agenten sei für die vorgegebene Anzahl von $A = 1.000$ Agenten eine Umwelt der Kantenlänge $l = 100$ definiert. Eine naheliegende Größe für den Nachbarschaftsradius wäre $r = l/6 \approx 17$, analog zu der populären Weisheit, dass jeder jeden über sechs Ecken kennt (vgl. [Watts 2003], S. 37 ff.). Ein solcher Radius würde jedoch bei der Dichte der Agenten von $A/l^2 = 10\%$ im vorgestellten Netzwerk zu einer sehr hohen Verbundenheit zwischen den Agenten führen, die man in einem sozialen Netzwerk in der Regel so nicht vorfindet. Entsprechend sei der Nachbarschaftsradius mit $r = 5$ etwas kleiner gewählt und der erweiterte Nachbarschaftsradius sei doppelt so groß wie der einfache Nachbarschaftsradius gewählt, also $r^* = 2r = 10$. Für den Anteil der Agenten mit erweitertem Radius sei $\varphi = 25\%$ angenommen. Das so konstruierte Netzwerk hat, bezogen auf den Durchschnitt zehn zufällig gewählter Konstruktionen, im Mittel neun Verbindungspartner je Agent, die sich wie in Abbildung 25 gezeigt verteilen. Der Median der Anzahl Verbindungspartner ist hierbei acht. Wie ersichtlich wird, deckt die Stichprobe ein breites Spektrum ab. Es existieren sogar einzelne Agenten ohne Verbindungspartner und die maximale Anzahl Verbindungspartner beträgt 29.




Abbildung 25: Verteilung der Anzahl Verbindungspartner im Netzwerk

Quelle: eigene Berechnung und Darstellung

In empirischen Studien werden ähnliche Charakteristika sozialer Netzwerke der Mobilfunkkommunikation präsentiert. In einer Befragung unter Studenten identifizieren [Birke und Swann 2005] durchschnittlich fünf Gesprächspartner, mit denen die Umfrageteilnehmer regelmäßig telefonieren. [Schnorf 2008] (S. 145 ff.) findet bei der Analyse anonymisierter Verbindungsdaten eines Mobilfunkanbieters in der Schweiz einen Durchschnitt von 10,6 Gesprächspartnern bei einem Median von sieben, wobei der Autor im Gegensatz zu der in der vorliegenden Arbeit verwendeten Modellierung eine näherungsweise Exponentialverteilung der Daten identifiziert.

Den bisher in Kapitel 4.3.3 nur qualitativ skizzierten Kundensegmenten werden nun in Tabelle 2 quantitative Präferenzwerte zugeordnet, wobei ein voller Kreis die höchste Ausprägung von vier und ein leerer Kreis die niedrigste Ausprägung von null repräsentiert:

↓ Segment		Nachfrage	Bedeutung der Entscheidungsattribute				
			(A1) Nachfrage- befriedigung	(A2) Kosten	(A3) Attrak- tivität	(A4) Netzwerk	(A5) Treue
	Kalibrierungsfaktor	3	0,7	2	5	20	22
I	Geschäftliche, nicht preis- sensitive Vieltelefonierer	●	●	◐	◑	◒	●
II	Geschäftliche, preissensitive Vieltelefonierer	●	◐	◑	◑	◒	◑
III	Private Vieltelefonierer	◐	◒	●	◐	◐	◒
IV	Private Durchschnittstele- fonierer	◒	◐	◑	◒	●	◐
V	Private Wenigtelefonierer	◐	◐	◑	◐	●	◐

● viel (4) ... ○ wenig (0)

Tabelle 2: Präferenzcharakteristika der Kundensegmente

Quelle: eigene Darstellung

Um die unterschiedlichen Skalen der Attribute (vgl. Kap. 4.3.1) vergleichbar zu machen, werden die Präferenzwerte aus Tabelle 2 noch mit einem ebenfalls aufgelisteten attribut-spezifischen Kalibrierungsfaktor multipliziert und ergeben so die Gewichte β^A für die Nutzenfunktion des Entscheidungsmodells (vgl. S. 76). Beispielsweise berechnet sich für die Nachfragebefriedigung (Attribut A1) für geschäftliche, nicht preissensitive Vieltelefonierer (Segment I) ein Gewicht $\beta^{A1} = 0,7 \cdot \bullet = 0,7 \cdot 4 = 2,8$. Die jeweilige Nachfrage des Segments wird durch Multiplikation des Präferenzwerts mit dem Kalibrierungsfaktor und anschließender Quadratur berechnet. Die so erzielten durchschnittlichen Nachfragewerte orientieren sich an den empirischen Durchschnittswerten im Markt, wobei nur die Nachfrage zu Mobilfunk-Gegenstellen berücksichtigt wird, da sich bei solchen Telefonaten die untersuchten Effekte besonders prägnant auswirken. Zusammengefasst ergeben sich die in Tabelle 3 aufgelisteten Werte für die Gewichte der Nutzenfunktion sowie für die Nachfrage:

↓ Segment		Höhe der Nach- frage (min)	Gewichte β^A der Nutzenfunktion				
			(A1) Nachfrage- befriedigung	(A2) Kosten	(A3) Attrak- tivität	(A4) Netzwerk	(A5) Treue
I	Geschäftliche, nicht preis- sensitive Vieltelefonierer	144	2,8	2	15	40	88
II	Geschäftliche, preissensitive Vieltelefonierer	144	2,1	6	15	40	66
III	Private Vieltelefonierer	81	1,4	8	5	20	44
IV	Private Durchschnittstele- fonierer	36	0,7	6	10	80	22
V	Private Wenigtelefonierer	9	0,7	6	5	80	22

Tabelle 3: Nachfrage und Gewichte der Nutzenfunktion nach Kundensegmenten

Quelle: eigene Darstellung

Der Leser sei explizit darauf hingewiesen, dass die Ermittlung dieser Segmente und die gewählten Wertebelegungen auf einer Reihe grober Annahmen und auf der Markteinschätzung des Autors beruhen, die mithilfe der Beurteilungen von Marktexperten plausibilisiert wurde. Sowohl die Segmentierung selbst als auch die Präferenzwerte innerhalb der Segmente erheben aber nicht den Anspruch, ein passgenaues Abbild der Realität darzustellen.

Jeder Anbieter offeriert das volle Tarifspektrum aus Vertrags-, Zeit- und Pauschaltarif zu den in Tabelle 10 aufgelisteten Konditionen. Es handelt sich hierbei um eine experimentell ermittelte Bepreisung des Tarifportfolios mit dem ausschließlichen Ziel, konstante Marktanteile während des dynamischen Ablaufs der Simulation zu erhalten. Offensichtlich stellen diese Preise demnach auch keine marktübliche Bepreisung eines typischen Tarifportfolios dar.

Anbieter	Tariftyp	Minutenpreis	Grundgebühr	Inklusivminuten
A	Vertrag	0,75 €	11 €	50
	Zeit	0,46 €	-	-
	Pauschal	-	45 €	∞
B	Vertrag	0,12 €	26 €	50
	Zeit	0,46 €	-	-
	Pauschal	-	31 €	∞
C	Vertrag	0,50 €	18 €	50
	Zeit	0,97 €	-	-
	Pauschal	-	22 €	∞
D	Vertrag	0,28 €	21 €	35
	Zeit	0,37 €	-	-
	Pauschal	-	22 €	∞

Tabelle 4: Preiskomponenten der angebotenen Tarife

Quelle: eigene Darstellung

Abgeleitet von der Positionierung der Anbieter auf dem deutschen Mobilfunkmarkt seien folgende Nutzenwerte für die Attraktivität der Anbieter definiert: Anbieter A = 4, Anbieter B = 4, Anbieter C = 3 und Anbieter D = 2. Dies entspricht der Marktstellung von T-Mobile (analog zu Anbieter A) und Vodafone (Anbieter B) als Marktführer, während E-Plus (Anbieter C) und O₂ (Anbieter D) jeweils mit einem späteren Markteintritt sowie einer eher preisfokussierten Außendarstellung nur eine geringere Attraktivität verbuchen können.

Hinsichtlich der zu Beginn der Simulation vorhandenen Tarife der Kundenagenten sei die in Tabelle 5 gezeigte Verteilung vorgegeben. Die Restlaufzeit des jeweils individuellen Tarifs eines Agenten wird zufällig aus einer diskreten Gleichverteilung auf dem Intervall [0; 12] gewählt. Ein Anteil von 10 % der Kunden hat zu Beginn der Simulation keinen Tarif bei einem der Anbieter abgeschlossen, auch diesen Agenten wird entsprechend eine angenommene Restlaufzeit zugeordnet, da auch eine solche Entscheidung nicht sofort revidiert wird. Die gewählte Aufteilung der Marktanteile ist vergleichbar mit der Stellung der

jeweiligen Mobilfunkanbieter im deutschen Markt. Die Verteilung zwischen den Tariftypen entspricht näherungsweise den von [Gerpott 2009] in einer empirischen Studie unter Studenten ermittelten Anteilen, dort haben 60 % der Befragungsteilnehmer einen Vertragstarif, 20 % einen rein nutzungsabhängigen Zeittarif und 20 % einen Pauschaltarif.

	Anbieter A	Anbieter B	Anbieter C	Anbieter D	
Vertragstarif	20 %	20 %	5 %	10 %	55 %
Zeittarif	5 %	5 %	6 %	2 %	18 %
Pauschaltarif	5 %	5 %	4 %	3 %	17 %
	30 %	30 %	15 %	15 %	90 %

Tabelle 5: Initiale Markt- und Tarifanteile

Quelle: eigene Darstellung

Eine konkrete Belegung des Störterms ε der Nutzenfunktion des Entscheidungsmodells ergibt sich durch Ziehung einer Zufallszahl aus einer Gumbel(1; 1) –Verteilung und anschließender Multiplikation dieser Realisation mit dem Faktor zehn. Dies führt zu einer experimentell ermittelten plausiblen Streuung des Entscheidungsverhaltens der Agenten.

Zusammengefasst ergeben sich die in der folgenden Tabelle 6 aufgelisteten Parameterwerte für die prototypische Implementierung:

Parameter	Parameterwert
Modellperioden	36
Mindestvertragslaufzeit	12 Perioden
Anzahl Agenten A	1.000
Netzwerk Kantenlänge l	100
Nachbarschaftsradius r	5
Erweiterter Nachbarschaftsradius r^*	10
Anteil der Agenten mit erweitertem Radius φ	25 %
Gewichte β^A der Nutzenfunktion	siehe Tabelle 3
Nachfrage der Agenten	siehe Tabelle 3
Preiskomponenten der angebotenen Tarife	siehe Tabelle 4
Attraktivität der Anbieter	A = 4, B = 4, C = 3 und D = 2
Initiale Markt- und Tarifanteile	siehe Tabelle 5
Verteilung des Störterms ε der Nutzenfunktion	Gumbel(1; 1) · 10

Tabelle 6: Übersicht Parameterwerte des Simulationsmodells

Quelle: eigene Darstellung

4.6. Implementierung des Prototyps in der Simulationsumgebung AnyLogic

Unter den in Kapitel 3.3.3 diskutierten agentenbasierten Simulationsumgebungen bietet sich aus verschiedenen Gründen AnyLogic für eine Implementierung an. Diese kommerzielle Software zeichnet sich für die vorliegende Anwendung gegenüber anderen Lösungen zu-

nächst durch eine umfangreiche grafische Oberfläche zur Visualisierung der Simulation aus (wie bereits in Kap. 4.4 illustriert). Darüber hinaus ist die Anbindung von Techniken zur simulationsbasierten Optimierung vorgesehen und mit OptQuest wird auch ein entsprechendes Paket mitgeliefert. In besonderem Maße wird für die vorliegende Arbeit auch die Möglichkeit genutzt, innerhalb von AnyLogic jedes Element der Simulation über die Programmiersprache Java ansprechen zu können und das Modell sowohl mit eigenen als auch externen Java-Klassen zu erweitern. Damit deckt AnyLogic alle für die Anwendung in dieser Arbeit erforderlichen Funktionalitäten ab.

In AnyLogic erstellte Simulationsmodelle haben jedoch den einschneidenden Nachteil, dass der Quellcode des Modells in ein proprietäres Datenformat verpackt ist, das sich nur innerhalb von AnyLogic verwenden lässt. Einem Austausch des Modells mit anderen Forschern oder Anwendern sind deshalb insofern Grenzen gesetzt, als dass der Empfänger ebenfalls über eine zur verwendeten Version kompatible Lizenz von AnyLogic verfügen muss. Genau deshalb wurde im Verlauf dieses Kapitels eine detaillierte Beschreibung des Simulationsmodells geliefert, die nicht nur eine inhaltliche, sondern auch eine technische Nachvollziehbarkeit auch ohne einen Einblick in den Quellcode sicherstellt.

Zur Verwendung kommt AnyLogic in der Version „6.4 advanced educational“. Diese Version für Bildungseinrichtungen hat die Beschränkung, dass kein Import von Simulationsparametern und Daten sowie kein Export von Simulationsergebnissen von und nach Microsoft Excel möglich ist. Dieses Manko wird durch die Einbindung von POI-HSSF²⁹ (Version 3.5 beta5) umgangen, einem freien Interface zum Zugriff auf Excel-Daten aus Java heraus. Für die effiziente Verarbeitung von Java-Collections bestehend aus primitiven Datentypen kommt außerdem die ebenfalls freie Klassenbibliothek GNU Trove³⁰ (Version 2.0.4) zum Einsatz und schließlich als Java-Laufzeitumgebung das „Java SE Runtime Environment Version 1.6“.

Die Simulation läuft inklusive der Aufbereitung der in Kapitel 4.4 gezeigten Statistiken und Visualisierungen auf einem Computer mit Intel Core2Duo T7500 Prozessor mit 2,2 GHz und 2 GB Arbeitsspeicher unter Windows 7 (32bit) ungefähr acht Minuten bei einem Load von ca. 80 % auf einem der Prozessorkerne, wobei diese Laufzeit mit einer hohen Varianz behaftet ist. Von außen ist kaum nachvollziehbar, was AnyLogic zu diesen unterschiedlichen Laufzeiten veranlasst. Die Unterschiede gehen weit über das bei Java übliche variable Laufzeitverhalten hinaus. Auch die absolute Höhe der durchschnittlichen Laufzeit wirft Fragen auf und deutet auf eine ineffizient implementierte oder zumindest schlecht mit der Anzahl der Agenten skalierende Simulationsumgebung hin. An dieser Stelle verschließt sich AnyLogic jedoch durch eine weder quellenoffene noch ausreichend dokumentierte Implementierung dem Auge des interessierten Programmierers, weshalb diesen Fragen nicht weiter nachgegangen werden konnte.

²⁹ <http://poi.apache.org/spreadsheet/index.html>, abgerufen am 25. Februar 2010.

³⁰ <http://trove4j.sourceforge.net/>, abgerufen am 25. Februar 2010.

In der Literatur finden sich dokumentierte Anwendungen der ABS auf Basis von AnyLogic nur sehr vereinzelt. Lediglich [Garifullin et al. 2007] zeigen die Implementierung eines einfachen Marktmodells, viele der dort gezeigten Modellierungsaspekte finden sich analog auch im vorliegenden Modell des Mobilfunkmarktes. Auf einem generischen Dienstleistungsmarkt konkurrieren bei diesen Autoren die Anbieter mit Tarifen um die Nachfrage der Kunden, welche wiederum die für ihr Nutzungsverhalten günstigste Tarifoption suchen. Die Kundenagenten wählen einen Tarif anhand eines Entscheidungsmodells, das die Ausprägungen der einzelnen Entscheidungsattribute quantitativ bewertet, gewichtet und zu einem Nutzenwert addiert. Als entscheidungsrelevant werden hierbei neben dem Preis zur Befriedigung der individuellen Nachfrage die Qualität, optionale Zusatzleistungen, Werbung, Empfehlungen von Händlern sowie insbesondere die Produktentscheidungen aus dem Umfeld des Kunden, z. B. im Familien- oder Freundeskreis, berücksichtigt. Sobald der Nutzen einer Alternative den des bisher gewählten Tarifs um einen bestimmten Schwellenwert (äquivalent zu einer Loyalität gegenüber dem bisherigen Anbieter) übersteigt, wechselt der Kunde zu einem anderen Anbieter. Mit der Simulation dieses Modells sollen laut den Autoren die Höhe und Struktur der Nachfrage sowie die Marktanteile der Anbieter geschätzt werden können.

4.7. Diskussion, Anwendung und mögliche Erweiterung

In Verlauf dieses Kapitels wurde die Abbildung eines Mobilfunkmarktes in einem agentenbasierten Simulationsmodell dargestellt, mit einem besonderen Fokus auf dem individuellen Entscheidungsverhalten der Kunden, das in diesem Markt signifikant von Netzwerkeffekten geprägt ist. Obwohl das Modell an vielen Stellen einen starken Bezug zum realen System des deutschen Mobilfunkmarktes herstellt, ist das gewählte Abstraktionsniveau lediglich hinreichend, um eine prototypische Modellierung dieses Marktes zu bewerkstelligen. Für ein praxisgerechtes Decision-Support-System zur Unterstützung der Mobilfunkanbieter bei taktischen bis strategischen Preisentscheidungen wäre eine detailliertere Modellierung insbesondere der verschiedenen Tarifstrukturen am Markt und des individuell sehr unterschiedlichen Entscheidungsverhaltens der Kunden notwendig. Ziel dieses Kapitels war es jedoch lediglich, ein zumindest praxisnahes Anwendungsfeld für die in den folgenden Kapiteln diskutierte simulationsbasierte Optimierung zu entwerfen. Diesen Anspruch erfüllt die vorgestellte Modellierung uneingeschränkt.

Anhand der vorliegenden Arbeit lässt sich gut nachvollziehen, welche Einschränkungen aus einer Modellierung dieses Systems mit einem klassischen Makromodell resultiert hätten. Zwar lassen sich auf aggregierter Ebene Gleichungen für Diffusionsraten des Tarifportfolios (Zu- und Abnahme der Marktanteile) angeben und daraus die Umsätze der Anbieter ableiten, diese Diffusionsraten können dann aber nur auf aggregierten Inputgrößen aufbauen, z. B. dem Preis oder dem bisherigen Marktanteil. Aufgrund der im Markt wirkenden Netzwerkeffekte spielt jedoch der jeweils lokale (für jeden Kunden individuelle) Marktanteil eine entscheidende Rolle für die Auswahl eines Tarifs. Somit können makroskopisch definierte Diffusionsraten den Entscheidungsprozess der Kunden nur unzureichend abbilden.

Das vorgestellte Modell zeigt in seiner inhaltlichen Ausrichtung und wissenschaftlichen Fundierung große Ähnlichkeiten zu dem in [Frels et al. 2005] und [Frels et al. 2006] beschriebenen Simulationsmodell „Standard-Scape“. Dort werden die Entscheidungen von Kunden zwischen zwei konkurrierenden technischen Produkten auf einem Markt mit Netzwerkeffekten dargestellt. In die Nutzenfunktion gehen dabei der Wert des Produkts, ebenso sein Preis, die Größe des aktuell in der Nachbarschaft vorhandenen wie auch des zukünftig insgesamt erwarteten Netzwerks dieses Produkts sowie zu berücksichtigende Wechselkosten mit ein. Die einzelnen Teilnutzen werden mit empirisch via Conjoint-Analyse ermittelten Faktoren gewichtet und zu einem Gesamtnutzen addiert. Zufällige Entscheidungen werden dadurch modelliert, dass die Agenten stochastisch gesteuert manchmal auf die Entscheidung für ein besseres Produkt verzichten, und dass sie ebenfalls stochastisch ihre Erwartungen an die zukünftige Netzwerkgröße variieren. Abermals analog zu der vorliegenden Arbeit werden die Auswirkungen verschiedener Preisstrategien der Anbieter auf Marktanteile und Gewinne untersucht, allerdings mit einem Fokus auf die gesteuerte Variation der Preise über den Zeitverlauf im Rahmen einer Penetrationsstrategie. Auch die Ergebnisse dieser Studie bestätigen, welchen signifikanten Einfluss Netzwerkeffekte auf das Entscheidungsverhalten der Kunden in vernetzten Märkten haben.

An möglichen Erweiterungen des Modells mangelt es nicht, vor allem auch deshalb, weil an vielen Stellen mit vereinfachenden und generalisierenden Annahmen gearbeitet wurde. Im Folgenden seien die aus Sicht des Autors interessantesten und für weiterführende Forschungsaktivitäten aussichtsreichsten Erweiterungsmöglichkeiten vorgestellt.

Explizit nicht im Nutzenmodell berücksichtigt wurden über den Preis hinausgehende tarifspezifische Nutzenattribute, wie sie von [Stingel 2008] (Kap. 3.2.2) herausgearbeitet werden. Vor allem der bereits in Kapitel 2.1.2 erwähnte Versicherungseffekt einer Flatrate und der Taxametereffekt im Rahmen einer Pauschalvergütung wären geeignete Kandidaten für eine Erweiterung des Nutzenmodells. Analog zu den Erkenntnissen aus [Stingel 2008] (Kap. 5.5) sollten diese Nutzenattribute den Gesamtnutzen von Pauschaltarifen erhöhen. Beispielsweise modellieren [Lambrecht und Skiera 2006b] die Präferenz für eine Flatrate (den sog. Flatrate-Bias) durch ein zusätzliches Entscheidungsattribut, das die Risikominimierung bewertet und bei einer Flatrate einen positiven Wert annimmt, da der Kunde in einem solchen Tarif vor unerwartet hohen Kosten geschützt ist. Demgegenüber repräsentieren reinnutzungsabhängige Zeittarife eine erhöhte Flexibilität. Auch dies könnte entsprechend mit einem Nutzenäquivalent modelliert und bewertet werden.

Die vorliegende Modellierung ist an einigen Stellen geprägt von statischen Größen, so ist z. B. das Netzwerk der Kundenagenten statisch definiert, ebenso die Bepreisung des Tarifportfolios der Anbieter und die Gewichte der Nutzenfunktion. Alle diese Aspekte haben im realen System jedoch eher einen im Laufe der Zeit veränderlichen Charakter. Bezogen auf das soziale Netzwerk lässt sich diese Vereinfachung sicher akzeptieren, da Veränderungen hier kaum zu strukturell abweichenden Simulationsergebnissen führen dürften. Anders stellt sich das bei den Preisen dar, diese sind im realen Markt häufig im Fluss und stellen insbesondere einen Hebel zur Reaktion auf Konkurrenzangebote dar. Eine mögliche Erweiterung des Modells wäre entsprechend ein vorgegebener, aber eben nicht konstanter Ver-

lauf der Preise des Tarifportfolios (z. B. zur Abbildung einer sog. Skimming- oder Penetrationsstrategie), oder die komplette Variabilisierung der Preise mittels Anbieter-Agenten, die einer zu definierenden Strategie folgend ihre Preise dynamisch anpassen und so z. B. auf die Nachfrage oder auf Angebote der Konkurrenz reagieren (vgl. Dynamic Pricing, siehe z. B. [Gönsch et al. 2009]). Bei der Analyse eines noch nicht komplett entwickelten Marktes könnte es außerdem interessant sein, die Gewichte β^A der Nutzenfunktion (siehe S. 76) über den Simulationsverlauf hinweg variabel zu gestalten, um so dem sich entwickelnden Fokus der Kunden weg von reinen Preiserwägungen hin zu einer Wertschätzung von Service und Qualität gerecht zu werden (vgl. [Kreye 2005], Kap. 3.4.1). Die Attraktivität der Anbieter ist im vorgestellten Modell ebenfalls statisch vorgegeben, wenngleich einleuchtend ist, dass sich diese mit wachsendem Markterfolg eines Anbieters auch verändert. Diesen Effekt könnte man dadurch modellieren, dass man zum konstanten Attraktivitätswert einen Wert addiert, der den aktuellen Marktanteil des betrachteten Anbieters abbildet, gegebenenfalls lediglich bezogen auf die Nachbarschaft des jeweiligen Kunden. Die bereits diskutierte Einschränkung, dass derartige Erweiterungen die Nachvollziehbarkeit der komplexen Wirkungszusammenhänge erheblich erschweren, gilt es hierbei besonders zu berücksichtigen.

Die Modellierung einzelner Kunden bietet außerdem die Möglichkeit, diese mit maßgeschneiderten Angeboten zu bedienen und so eine individuelle Preisdifferenzierung zu praktizieren. Solche Maßnahmen können z. B. dazu verwendet werden, Kunden, die durch ihre exponierte Positionierung im Netzwerk einen erhöhten Einfluss auf die Netzwerkeffekte haben, durch Sonderkonditionen für das eigene Tarifangebot zu gewinnen und so in der lokalen Umgebung eine Sogwirkung zu erzeugen. Eine solche Strategie muss sich jedoch im untersuchten Markt nicht zwangsläufig positiv auf den erzielten Umsatz des Anbieters auswirken (vgl. die Zusammenfassung der Studie von [Liehr 2005] auf S. 70). Deshalb erscheint es sinnvoll, deren Auswirkungen im Modell vorab zu untersuchen.

Bei der Modellierung der Nachfrage der Kunden wurde in dieser Arbeit bisher davon ausgegangen, dass die Nachfrage nicht preissensitiv ist und deshalb einer Grundnachfrage entspricht. Zweifellos führen aber sinkende Kosten (oder umgekehrt attraktivere Produkte) zur Erschließung zusätzlicher Nachfrage für den Anbieter (vgl. [Rohlf's 1974] oder [Späth 1995], S. 138 ff.), wie man an der teilweise exzessiven Nutzung von Flatrateangeboten im realen Mobilfunkmarkt leicht sieht. Auch diese sogenannte induzierte Nachfrage könnte man im Modell berücksichtigen und z. B. die Nachfrage als Funktion abhängig vom Preis einer Mobilfunkminute modellieren.

5. Grundlagen der simulationsbasierten Optimierung

Die simulationsbasierte Optimierung (SBO) beschäftigt sich mit der Problemstellung, freie Parameterwerte einer Simulation als Variablen anhand eines aus dem Ablauf der Simulation abgeleiteten Zielkriteriums zu optimieren. Die Zielfunktion liegt dabei also nicht in expliziter Form vor, sondern ist nur durch den ressourcenintensiven Ablauf einer Simulation auswertbar. Somit weist die SBO erkennbare Ähnlichkeiten zur Optimierung auf Basis empirischer Experimente auf (vgl. [Bartz-Beielstein 2006], Kap. 2), ein Verfahren, das beispielsweise im Kontext klinischer Studien zur Wirksamkeit von Medikamenten verwendet wird. Ein stochastischer Simulationslauf entspricht hierbei der Durchführung eines Experiments, bei dem der Ausgang durch komplexe Wirkungszusammenhänge, nicht vollständig bekannte Umgebungsbedingungen oder Messungenauigkeiten im Detail unvorhersehbar beeinflusst wird.

Der üblicherweise stochastische Charakter der zugrunde liegenden Simulation stellt eine erhebliche Hürde für die SBO dar, da verschiedene Simulationsläufe mit identischen Variablenbelegungen nicht zu identischen Zielfunktionswerten führen müssen. Hierdurch können mögliche Lösungen des Optimierungsproblems unter- oder überschätzt werden, was sowohl den Ablauf der Optimierung als auch deren letztendliches Ergebnis entscheidend beeinflussen kann. Eine Verbesserung der Zielfunktion im Optimierungsverlauf kann deshalb sowohl einerseits das Resultat einer in der Tat besseren Lösung sein, als auch andererseits nur ein stochastischer Effekt, der sich bei einer erneuten Zielfunktionsauswertung potenziell entgegengesetzt ausprägt.

Praktische Problemstellungen der SBO sind in der Regel hochdimensional, d. h. mit einer großen Anzahl an freien Parametern. Die vollständige Enumeration aller möglichen Lösungen wäre entsprechend mit einem prohibitiv hohen Aufwand verbunden. Häufig ist die Struktur des Raumes der Zielfunktionsauswertungen darüber hinaus auch weitgehend unbekannt, weshalb ein Lösungsalgorithmus nie mit Sicherheit bei einem gefundenen lokalen Optimum auf ein globales Optimum schließen kann. Vielmehr besteht immer die Möglichkeit, dass sich unter den nicht untersuchten Lösungen eine neue beste Lösung befindet (vgl. [Spall 2004]).

Aus diesen Rahmenbedingungen der SBO ergibt sich die Notwendigkeit, spezielle Optimierungsansätze zu verwenden, die sowohl effizient sind als auch mit den stochastischen Schwankungen der Zielfunktionsauswertungen umgehen können. Durch die inhärente Stochastik muss auch das eigentliche Ziel einer Optimierung, die beste Lösung zu finden, relativiert werden (vgl. [Lin und Lee 2006]): Ziel ist vielmehr, eine möglichst gute Lösung zu finden und die Qualität dieser Lösung möglichst störungsfrei zu bewerten.

In der Literatur finden sich bereits einige Übersichten zu den verschiedenen möglichen Ansätzen der SBO. [Spall 2003] führt den Leser ausführlich in die Grundlagen und den praktischen Einsatz vieler der im Folgenden beschriebenen Verfahren ein. Speziell auf Optimierungsmethoden für diskrete Variablen beziehen sich [Swisher et al. 2004], während

[Spall 2004] kontinuierliche Optimierungsvariablen betrachtet. Neben einer Übersicht verschiedener Algorithmen der SBO referenzieren [Tekin und Sabuncuoglu 2004] jeweils auch eine Vielzahl praktischer Anwendungsfälle und [Fu 2002] sowie [Fu et al. 2005] erweitern den Überblick noch um verschiedene kommerzielle Optimierungslösungen zur SBO.

5.1. Betrachtetes Grundproblem

Bei der SBO wird eine zugrunde liegende Simulation repräsentiert durch eine stochastische Zielfunktion $\phi(\boldsymbol{\theta}, \mathbf{y})$ mit den n Optimierungsvariablen $\boldsymbol{\theta} = (\theta_1, \dots, \theta_n)$ (häufig auch Designvariablen oder Faktoren genannt) und den Zufallsvariablen \mathbf{y} , wobei sich der Wert der Zielfunktion für gegebene $\boldsymbol{\theta}$ und \mathbf{y} ausschließlich und reproduzierbar aus dem Ablauf der terminierenden (d. h. endlichen und nach dem Ablauf auswertbaren) Simulation ergibt. Ein Simulationslauf entspricht also einem Monte-Carlo-Prozess, bei dem eine Zielfunktionsauswertung für die verwendeten Werte der Optimierungsvariablen $\boldsymbol{\theta}$ sowie für eine bestimmte (ggf. im Rahmen von Verteilungsannahmen zufällig gewählte) Realisation der enthaltenen Zufallsvariablen \mathbf{y} ermittelt wird. Die stochastischen Einflüsse führen zu Schwankungen in ϕ beim Vergleich mehrerer unabhängiger Simulationsläufe, sodass eine einzelne Zielfunktionsauswertung als Summe aus einem angenommenen störungsfreien Zielfunktionswert $\phi(\boldsymbol{\theta})$ und einem stochastischen Störterm $\varepsilon(\boldsymbol{\theta}, \mathbf{y})$ angesehen werden kann (vgl. [Spall 2003], S. 8 f.). Der Zielfunktionswert wird so selbst zu einer Zufallsvariablen: $\phi(\boldsymbol{\theta}, \mathbf{y}) = \phi(\boldsymbol{\theta}) + \varepsilon(\boldsymbol{\theta}, \mathbf{y})$. Für die SBO ist es dabei unerheblich, ob die störungsfreie Zielfunktionsauswertung $\phi(\boldsymbol{\theta})$ überhaupt existiert (wie im Falle einer störungsfreien Simulation, die aber nur mit stochastischen Messfehlern behaftet ausgewertet werden kann), oder ob es systembedingt nur stochastische Auswertungen gibt (wie im Falle einer komplexen Simulation mit stochastischen Inputvariablen).

Erschwerend für die Optimierung wirkt sich aus, dass über die Simulation hinaus keine Informationen hinsichtlich des funktionalen Zusammenhangs zwischen Input $(\boldsymbol{\theta}, \mathbf{y})$ und Output $\phi(\boldsymbol{\theta}, \mathbf{y})$ vorliegen, welche die Berechnung von Gradienten ermöglichen würden; insbesondere ist mangels eines funktionalen Zusammenhangs keine Differenzierbarkeit gegeben. Diese Situation ist typisch für komplexe Simulationen. Ebenso ist a priori unbekannt, ob die Zielfunktion ein oder mehrere Optima besitzt. Der Simulator stellt also von außen betrachtet eine Blackbox dar, deren Auswertung einzig durch den Ablauf der Simulation möglich ist. Eine Optimierung ist folglich nur durch den Vergleich von Zielfunktionsauswertungen möglich, was als direkte Suche („direct search“, siehe [Trosset 2000]) klassifiziert wird.

Der schematische Ablauf einer SBO lässt sich wie in Abbildung 26 gezeigt beschreiben. Ausgehend von einer Lösung $\boldsymbol{\theta}^1$ wird mit einer konkreten Realisation der Zufallsvariablen \mathbf{y} die Simulation durchgeführt, was einer Auswertung der Zielfunktion $\phi(\boldsymbol{\theta}^1, \mathbf{y})$ entspricht. Ein Optimierungsalgorithmus verwendet die hierdurch gewonnenen Erkenntnisse möglichst geschickt, um darauf basierend eine neue (hoffentlich bessere) Lösung $\boldsymbol{\theta}^2$ zu erzeugen. Diese Lösung wird dann abermals mittels der Simulation bewertet. So setzt sich der Verlauf der Optimierung iterativ fort.




Abbildung 26: Schematischer Ablauf einer simulationsbasierten Optimierung

Quelle: eigene Darstellung

Das eigentliche Optimierungsziel besteht aus $\max_{\theta \in \Theta} E[\phi(\theta, y)]$, wobei $E[\phi(\theta, y)]$ den Erwartungswert der Zielfunktion darstellt und Θ der gültige Definitionsbereich der Optimierungsvariablen θ ist. [Gosavi 2003] (Kap. 7) nennt dieses Vorgehen deshalb auch die *parametrische SBO* eines stochastischen Systems, da letztendlich die im Durchschnitt bestmögliche Parametrisierung des Simulationssystems gesucht wird.

Der Definitionsbereich Θ kann sowohl durch Unter- und Obergrenzen, durch Diskretisierung als auch durch den expliziten Ausschluss einzelner Lösungskandidaten beschränkt sein. Eine solche Begrenzung ist auch in prinzipiell unbeschränkten Problemstellungen sinnvoll, um mit a priori bekannten Kontextinformationen den Suchraum einzuschränken und somit ein schnelleres Finden guter Lösungen zu ermöglichen. Minimierungsprobleme können durch geeignete Transformation leicht in Maximierungsprobleme überführt werden, weshalb die Darstellung in den folgenden Kapiteln lediglich auf Maximierungsprobleme ausgerichtet ist. Eine konkrete Wertebelegung der Optimierungsvariablen θ sei im Folgenden als *Lösungskandidat* des Optimierungsproblems bezeichnet, nach der Zuordnung einer quantitativen Bewertung über die Zielfunktion ϕ als *Lösung*.

Ein üblicherweise verwendeter Schätzer für den zu maximierenden Erwartungswert der Zielfunktion $E[\phi(\theta, y)]$ ist der Stichproben-Mittelwert $\mu = \frac{1}{m} \cdot \sum_{i=1}^m \phi_i(\bar{\theta}, y_i)$ der Zielfunktionsauswertungen $\phi_i(\bar{\theta}, y_i)$ von m voneinander unabhängigen Simulationen (so genannte *Replikationen*, vereinzelt auch Realisationen oder Beobachtungen genannt) mit einer identischen Wertebelegung der Optimierungsvariablen $\bar{\theta}$ (vgl. [Andradottir und Prudius 2009]), aber unterschiedlichen Realisationen der verwendeten Zufallsvariablen y . Im Gegensatz zur Zielfunktion $\phi(\theta, y)$ selbst, für die im Allgemeinen keine Verteilungsannahme aus der komplexen Simulation ableitbar ist, kann der Stichproben-Mittelwert μ nach dem Zentralen Grenzwertsatz als normalverteilt angenommen werden, wie [Chen et al. 2000] und [Kim und Nelson 2006] erklären und [Nakayama 2008] (insb. Abb. 4) an einem anschaulichen Beispiel demonstriert. Genau diese Eigenschaft wird sich bei der später beschriebenen Evaluation von Lösungen als nützlich erweisen.

Innerhalb der SBO wird der Stichproben-Mittelwert μ sowohl dazu verwendet, beste Lösungen aus einer Menge von Kandidaten zu identifizieren, als auch, um die Qualität einzelner Lösungskandidaten zu evaluieren. Der Anzahl der für einen solchen Monte-Carlo-Schätzer verwendeten Replikationen kommt eine entscheidende Bedeutung zu, da durch sie

die Genauigkeit der Schätzung von $\mu \cong E[\phi(\theta, y)]$ determiniert wird. Generell werden in der Literatur zehn (z. B. in [Law 2007], S. 503 f.) bis 30 Replikationen (z. B. in [Nakayama 2008]) als Untergrenze für die Ermittlung darauf basierender, aussagefähiger statistischer Kenngrößen angesehen. Unter der Annahme unabhängigen Rauschens kann man anhand des Zentralen Grenzwertsatzes (vgl. z. B. [Gosavi 2003], S. 27) zeigen, dass der inhärente Schätzfehler durch n Replikationen lediglich um den Faktor $1/\sqrt{n}$ zurückgeht. Bei praktischen Problemstellungen mit abhängigem Rauschen ist dieser Faktor eher noch geringer (vgl. [Spall 2003], S. 14).

Erst bei einer hinreichend großen Anzahl an Replikationen kann der Stichproben-Mittelwert effektiv als perfekte (rauschfreie) Funktionsauswertung angenommen werden (vgl. [Spall 2003], S. 50). Dies würde jedoch einen erheblichen Bedarf an Simulationsdurchläufen und damit in diesem Kontext knappen Ressourcen speziell bei Problemstellungen mit einer hohen Varianz in $\phi(\theta, y)$ nach sich ziehen (vgl. [Chen et al. 2000]). Daraus lässt sich die für die erfolgreiche Anwendung der SBO kritische Abwägung ableiten, wie viele Ressourcen auf die Suche nach einer guten bzw. der besten Lösung (*Exploration*) bzw. wie viele Ressourcen für die Schätzung des Zielfunktionswerts durch Mittelung mehrerer Simulationsläufe verwendet werden (*Evaluation*, siehe [Pichitlamken et al. 2006]). [Boesel, Nelson und Kim 2003] nennen diese Abwägung den „search versus selection trade-off“, [Lin und Lee 2006] die „balance between search and performance estimation“. Verwendet ein Algorithmus zu viele Ressourcen auf die Exploration, werden gute Lösungen zwar gefunden, für die Auswahl der besten Lösung hat der Stichproben-Mittelwert dann aber eine zu geringe Aussagekraft, da er noch mit einer erheblichen Unsicherheit behaftet ist. Umgekehrt kann man durch einen überzogenen Ressourceneinsatz bei der Evaluation zwar die Unsicherheit in der Bewertung einer Lösung eliminieren, dadurch sinkt aber auch die Chance, mit den dann zur Exploration übrig gebliebenen Ressourcen überhaupt gute Lösungen zu finden.

Die Lösung dieses Ressourcenkonflikts ist eine zentrale strategische Fragestellung der SBO, die nur unter sehr groben Annahmen hinsichtlich der Struktur des Raumes der Zielfunktionsauswertungen und der inhärenten Stochastik optimal lösbar wäre. Für praktische Problemstellungen ist deshalb ein heuristischer Ansatz notwendig, der entsprechend der Ausgangsproblemstellung die Exploration, d. h. die Suche nach einer guten Lösung, als primäres Ziel der SBO verankert. Die Evaluation hingegen ist nur ein notwendiges Mittel zum Zweck, die Allokation von Simulationsressourcen hierfür sollte entsprechend nur soweit erforderlich erfolgen, z. B. bis zur Erlangung einer geforderten stochastischen Signifikanz. Die Umsetzung dieser Aufteilung kann explizit durch eine Abtretung der Ressourcen anhand von Budgets an Simulationsläufen für die Evaluation erfolgen oder implizit durch die Definition von Abbruchbedingungen für die Evaluation bei einem iterativen Vorgehen.

5.1.1. Allokation von Replikationen

Für alle algorithmischen Ansätze der SBO stellt sich also die generelle Frage, wie viele Replikationen für eine bestimmte Lösung verwendet werden sollen, sowohl für die Identifikation einer besten Lösung aus einer abgegrenzten Menge von Lösungen als auch zur Evaluation des Zielfunktionswerts einer einzelnen Lösung. Wie im Folgenden gezeigt wird, bietet die Literatur für ersteren Problemkreis einen wahren Fundus an unterschiedlichen

Ansätzen, während der zweite Problemkreis bisher deutlich weniger Aufmerksamkeit erlangt hat, gleichwohl er fundamental relevant für alle Anwendungen der stochastischen SBO ist.

Für die Allokation von Replikationen zur Bestimmung einer besten Lösung aus mehreren (vorgegebenen) Lösungskandidaten findet man in der Literatur verschiedene Ansätze, bereits [Bechhofer et al. 1995] befassen sich mit diesem Thema. Allen gezeigten Ansätzen ist jedoch die Einschränkung gemein, dass sie eine a priori bestimmte Menge an Lösungskandidaten voraussetzen. In [Law 2007] (Kap. 9.4) wird z. B. erörtert, wie viele Replikationen man benötigt, um zwischen zwei Lösungskandidaten die bessere Lösung mit einer bestimmten Konfidenz auszuwählen, wobei die Anzahl der Replikationen für beide Lösungskandidaten variabel ist. [Alkhamis und Ahmed 2004] zeigen die praktische Anwendung eines solchen Konfidenzintervalls im Metropolis-Kriterium eines „Simulated Annealing“-Algorithmus.

Vor allem im Kontext mengenbasierter Algorithmen wird die Frage diskutiert, wie ein gegebenes Budget an stochastischen Simulationsläufen (entsprechend Zielfunktionsauswertungen) möglichst effizient auf eine bestimmte Menge verschiedener Lösungskandidaten verteilt werden kann, um diese zu beurteilen und zu ordnen (vgl. [Jaskowski und Kotlowski 2008]). Beispielsweise wird für jede Generation eines evolutionären Algorithmus eine Anzahl Simulationsläufe vorgegeben, die zwischen den zu untersuchenden Lösungskandidaten der Population aufgeteilt werden muss.

Eine ähnliche Zielsetzung steckt hinter dem OCBA-Ansatz („optimal computing budget allocation“, [Chen et al. 2000]). Hierbei werden die zur Verfügung stehenden Simulationsläufe so aufgeteilt, dass die Wahrscheinlichkeit maximiert wird, die beste Lösung innerhalb einer Menge von Lösungskandidaten zu identifizieren (vgl. z. B. [Fu et al. 2008] sowie für Anwendungen innerhalb eines „Nested Partitions“-Algorithmus [Shi und Chen 2000]).

[Lin und Lee 2006] gehen noch einen Schritt weiter und zeigen eine Möglichkeit, wie man verfügbare Ressourcen optimal zwischen der Exploration und der Evaluation verteilen kann. Eine pragmatische Faustregel für eben diese Problemstellung zeigt [Stroud 2001], indem er den möglichen Fehler des Stichproben-Mittelwerts einer mehrfachen Replikation mit der Varianz der betrachteten Population von Lösungen selbst vergleicht und darauf basierend über weitere Replikationen zur Evaluation oder eine Fortführung der Exploration entscheidet.

Darüber hinaus findet man in der Literatur weitere populäre Ansätze zur Selektion der Besten aus einer bestimmten Menge verschiedener Lösungskandidaten, die sich hauptsächlich im Nachweis der korrekten Selektion unterscheiden, siehe für einen Überblick z. B. [Branke et al. 2005], [Goldsman und Nelson 1998], [Inoue et al. 1999], [Kim und Nelson 2006], [Swisher et al. 2003] oder die sehr umfangreiche Vergleichsstudie [Branke et al. 2007] sowie für Anwendungen im Kontext evolutionärer Algorithmen [Boesel, Nelson und Ishii 2003], [Buchholz und Thümmel 2005] und [Lee et al. 2008]. Schließlich zeigen [Hong und Nelson 2005] eine rein sequenzielle Möglichkeit, wie man ohne das fortwährende Wechseln zwischen einzelnen zu untersuchenden Lösungskandidaten auskommt, was je nach

Implementierung und daraus resultierendem Wechselaufwand eine erhebliche Vereinfachung darstellen kann.

Die Evaluation eines einzelnen Lösungskandidaten anhand mehrerer Replikationen zur Ermittlung eines repräsentativen Zielfunktionswerts, der dem Erwartungswert der Verteilung der Simulationsergebnisse möglichst nahe kommt, wird hauptsächlich in der Grundlagenliteratur erörtert (z. B. in [Law 2007], Kap. 10). Für anwendungsbezogene Studien wird häufig lediglich eine vorgegebene Anzahl an Simulationsläufen je Lösungskandidat herangezogen. Die Wahl fällt dann auf zehn (z. B. in [Narzisi et al. 2006]), 30 (z. B. in [Nissen und Propach 1998]), 100 (z. B. in [Shi und Brooks 2007] oder [Barnes et al. 2010]), 200 (z. B. in [Stagge 1998]) oder 1.000 Replikationen (z. B. in [Rahmandad und Sterman 2008], S. 1003), ohne dass dies kausal begründet würde. Allenfalls wird anhand einer Sensitivitätsanalyse die für die konkrete Problemstellung notwendige Anzahl an Replikationen ermittelt, welche zu robusten Simulationsergebnissen führt (z. B. in [Biethahn und Nissen 1994]).

Neben den bereits eingehend diskutierten statistischen Kenngrößen Mittelwert und Varianz stellen je nach Problemstellung auch die Quantile eine relevante Information über den Charakter des zu evaluierenden Lösungskandidaten dar. [Alexopoulos 2006] zeigt, wie man diese anhand einer Stichprobe von Replikationen schätzen kann.

5.1.2. Sequenzielle Optimierung

Die in der vorliegenden Arbeit betrachtete Problemstellung weicht von den bisher diskutierten Fragen dadurch ab, dass die Menge der zu überprüfenden Lösungskandidaten nicht vorab fix definiert ist, sondern sich erst sequenziell durch den Ablauf des Optimierungsalgorithmus entwickelt. Dieses strukturelle Charakteristikum ist typisch für den Ablauf einer Optimierung und findet sich z. B. im allgemeinen Framework für Metaheuristiken von [Olafsson 2006] oder auch in der Implementierung der simulationsbasierten Optimierung mit OptQuest (vgl. die nachfolgenden Kap. 5.2.5 und 6.2.2). Das Entscheidungsproblem besteht dann darin, für jeden neu hinzukommenden Lösungskandidaten zu beurteilen, ob dieser besser ist als die bisher untersuchten Lösungen und somit eine neue beste gefundene Lösung darstellt. Obwohl diese Fragestellung bei vielen Algorithmen der SBO beantwortet werden muss, wird sie in der Literatur bis auf die im Anschluss zitierten Quellen nur selten explizit diskutiert. Gewisse Ähnlichkeiten weist dieses Entscheidungsproblem zu Fragestellungen innerhalb von „Screening & Selektion“-Mechanismen auf, wie sie in [Nelson et al. 2001] oder [Boesel, Nelson und Kim 2003] gezeigt werden.

Ein naheliegender Ansatz zur Umsetzung dieser sequenziellen Optimierung ist es, jeden neuen Lösungskandidaten zu evaluieren, mit der bisher besten gefundenen Lösung zu vergleichen und gegebenenfalls auszutauschen, falls dieser besser ist (vgl. [Hong und Nelson 2007]). In die Betrachtung geht also nur die jeweils beste Lösung ein, entsprechend können alle anderen – als schlechter identifizierten – Lösungen für die weiteren Evaluationen entfallen. Voraussetzung hierfür ist die Transitivität in der Bewertung der Lösungen, die allgemein lediglich im Fall einer Optimierung mit mehrdimensionalen Zielsetzungen verletzt sein könnte. Im Folgenden sei jedoch eine Einschränkung auf eindimensionale

Optimierungsprobleme getroffen, bei denen der Stichproben-Mittelwert μ als transitives Maß für die Bewertung von Lösungskandidaten herangezogen werden kann.

Bei der Evaluation eines jeden Lösungskandidaten ist vor jeder Replikation die zentrale Frage zu klären, ob dieser Lösungskandidat nochmals gesampelt werden soll oder ob mit dem nächsten Lösungskandidaten weiter verfahren werden soll. Hierzu findet man in [Hong und Nelson 2007] zwei Prozeduren, die für eine (un-)begrenzte Anzahl zu überprüfender Lösungskandidaten eine vorgegebene Wahrscheinlichkeit α einer falschen Auswahlentscheidung zwischen zwei Lösungen auf alle im Laufe der Optimierung zu treffenden Entscheidungen verteilen und so die richtige Entscheidung für die beste Lösung mit einer korrespondierenden Wahrscheinlichkeit von $1 - \alpha$ garantieren können. Die Autoren bemerken aber zurecht, dass diese Garantie zum Preis eines hohen Aufwands an Replikationen erkaufte wird, was nur bei Optimierungsproblemen mit eng begrenztem Lösungsraum eine realistische Option darstellt. Außerdem setzen beide Prozeduren die Vorgabe einer Indifferenzschwelle voraus, unterhalb derer die Differenz zweier Lösungen im betrachteten Problemkontext nicht mehr relevant ist und deshalb eine Auswahlentscheidung zwischen diesen Lösungen immer ein korrektes Ergebnis liefert. Für praktische Problemstellungen ist die Angabe einer solchen Indifferenzschwelle häufig jedoch problemlos möglich, bei monetären Zielgrößen kann dies z. B. die kleinste Währungseinheit sein.

Im Folgenden werden alternativ zu den Prozeduren von [Hong und Nelson 2007] unter Einbeziehung verschiedener zitierte Ansätze aus der Literatur mehrere praktisch anwendbare Prozeduren zur Einbettung in gängige Optimierungsalgorithmen vom Autor entwickelt und vorgestellt, anhand derer sequenziell entschieden werden kann, ob für einen Lösungskandidaten weitere Replikationen erfolgen sollen. Sie geben zwar aus Effizienzgründen keine Garantie einer richtigen Auswahlentscheidung, ermöglichen aber eine „gute“ Entscheidung unter Beschränkung des benötigten Budgets an Replikationen. Das *Evaluationskriterium1* bezieht dabei lediglich den bis dato berechneten Stichproben-Mittelwert sowie die Anzahl der hierfür durchgeführten Replikationen in die Entscheidung mit ein. Das *Evaluationskriterium2* hingegen berücksichtigt zusätzlich die Varianz in der Verteilung der Zielfunktionswerte der Replikationen, ein Ansatz, der sich auch bei [Hong 2006] als vorteilhaft herausgestellt hat. Es stellt deshalb eine schärfere Schranke für den frühzeitigen Ausschluss schlechter Lösungen dar, und das bei einer potenziell gleichen oder sogar geringeren Fehlerwahrscheinlichkeit erster Art (dem fälschlichen Ausschluss einer guten Lösung). So kann das insgesamt zur Verfügung stehende Simulationsbudget effizienter auf die zu untersuchenden Lösungskandidaten aufgeteilt werden. Das *Evaluationskriterium3* und das *Evaluationskriterium4* repräsentieren mögliche fortgeschrittene Ansätze, die aber aufgrund weitergehender Anforderungen an die Implementierung im Verlauf dieser Arbeit nicht weiter betrachtet werden. Allen diesen Ansätzen ist gemein, dass sie zwar durchaus bekannte und verbreitete statistische Tests einsetzen, deren Anwendung für die SBO in der wissenschaftlichen Literatur bisher aber kaum diskutiert wurde.


Die betrachteten Evaluationskriterien weisen alle eine gewisse Wahrscheinlichkeit auf, eine falsche Auswahlentscheidung zu treffen und damit eine Lösung zu favorisieren, die sich bei einer noch eingehenderen Untersuchung als inferior herausgestellt hätte. Je nach ver-

wendetem Optimierungsalgorithmus ist die Schädlichkeit einer falschen Auswahlentscheidung aber begrenzt, da generell jede falsche Auswahlentscheidung durch eine klar bessere Lösung im weiteren Verlauf der Optimierung relativiert wird. Auswahlfehler sind im Allgemeinen also nicht additiv, sondern schlagen sich lediglich in einer verminderten Lösungsgeschwindigkeit (Effizienz) des Algorithmus nieder. Selbst wenn eine beste Lösung bei der Auswahl verworfen wurde, so bestehen trotzdem gute Chancen, dass ein Algorithmus bei der weiteren Suche diese Lösung nochmals findet.

Die Prozedur *Evaluationskriterium1* prüft als Eingangsvoraussetzung nach S^{min} Replikationen, ob der auf dieser Datenbasis ermittelte Stichproben-Zielfunktionswert $\mu_{S^{min}}$ zumindest 50 % des als Referenz gegebenen Zielfunktionswerts μ^* erreicht. Ist dies der Fall, so werden weitere Replikationen S durchgeführt, solange der aktuelle Status $[S; \mu_S]$ oberhalb der linearen Interpolation der Punkte $[S^{min}; (1/2) \cdot \mu^*]$ und $[S^{max}; \mu^*]$ liegt (vgl. Abbildung 27). In diesem Fall kann die gerade untersuchte Lösung weiterhin als vielversprechender Kandidat für eine neue beste Lösung angesehen werden. Sind S^{max} Replikationen erreicht, so wird durch einen Vergleich des Stichproben-Mittelwerts $\mu_{S^{max}}$ mit dem Referenz-Zielfunktionswert μ^* entschieden, ob eine neue beste Lösung gefunden wurde. Bei vorzeitigem Abbruch $S < S^{max}$ bleibt die bisher beste Lösung erhalten. Da dieses Kriterium lediglich auf dem Vergleich von Stichproben-Mittelwerten beruht, ist für dessen Verwendung keine Verteilungsannahme notwendig.

Prozedur: Evaluationskriterium1

- Gegeben: S^{min} , S^{max} , Referenz-Zielfunktionswert μ^*
- Durchführung von mindestens S^{min} Simulationsläufen
- Durchführung weiterer Simulationsläufe, solange für den Stichproben-Mittelwert μ_S der bisherigen S Simulationsläufe gilt: $\mu_S > \frac{1}{2} \cdot \mu^* \cdot (1 + \frac{S - S^{min}}{S^{max} - S^{min}})$ (vgl. den schraffierten Bereich der Abbildung 27)
- Abbruch nach maximal S^{max} Simulationsläufen, Rückgabe von $\max\{\mu^*, \mu_S\}$ zusammen mit der korrespondierenden Lösung

Abbildung 27: Replikationsverlauf unter dem *Evaluationskriterium1*

Quelle: eigene Darstellung

Demgegenüber verwendet das *Evaluationskriterium2* das Konfidenzintervall des Stichproben-Mittelwerts $\mu_S \pm t_{S-1, 1-\alpha/2} \cdot (\sigma_S / \sqrt{S})$ (vgl. [Law 2007], S. 500 f., [Alexopoulos 2006] oder [Hoad et al. 2010]) unter Normalverteilungsannahme (vgl. S. 97) für die sequenzielle Entscheidung, ob bereits mit der vorgegebenen Konfidenz ausgeschlossen werden kann, dass die überprüfte Lösung besser ist als die Referenzlösung (vgl. Abbildung 28). Somit fließen sowohl die Stichproben-Varianz als auch die Höhe des Stichproben-Mittelwerts in die Bestimmung der Anzahl der Replikationen mit ein. Befindet sich bei Erreichen von S^{max} Replikationen der Referenzwert μ^* noch innerhalb des Konfidenzintervalls von $\mu_{S^{max}}$, so wird durch einen Vergleich der beiden Stichproben-Mittelwerte $\mu_{S^{max}}$ und μ^* entschieden, ob eine neue beste Lösung gefunden wurde. Eine statistische Konfidenzaussage ist dann aber nicht möglich. Stellt sich bereits für $S < S^{max}$ mit Konfidenz heraus, dass die überprüfte Lösung eine neue beste Lösung darstellt, so werden trotzdem S^{max} Replikationen durchgeführt, um in diesem für das Ergebnis der Optimierung sensiblen Bereich die Normalverteilungsannahme zu untermauern sowie eine Konsistenz mit später überprüften Lösungen herzustellen, bei denen dann diese Lösung als Referenzwert in die Evaluation eingeht. [Hoad et al. 2010] zeigen, wie man den auch nach Erreichen des vorgegebenen Konfidenzniveaus noch generell möglichen Auswahlfehler durch eine Hinzunahme weiterer Replikationen („look-ahead“) nahezu eliminieren kann. Der Ansatz erscheint im in dieser Arbeit betrachteten Kontext aber nicht zielführend, da sich die Steuerung des Optimierungsverlaufes wie bereits

dargestellt recht robust gegenüber dem Verwerfen guter Lösungen verhält, diese Simulationsressourcen also effizienter für die Untersuchung weiterer Lösungskandidaten verwendet werden können.

Prozedur: Evaluationskriterium2

- Gegeben: S^{\min} , S^{\max} , Referenz-Zielfunktionswert μ^* , Konfidenz $(1 - \alpha)$
- Durchführung von mindestens S^{\min} Simulationsläufen
- Berechnung je weiterem Simulationslauf:
 - Stichproben-Mittelwert μ_S der bisherigen S Simulationsläufe,
 - Stichproben-Varianz σ_S^2 der bisherigen S Simulationsläufe,
 - kritischer Punkt $t_{S-1, 1-\alpha/2}$ der Student t-Verteilung,
 - maximaler Fehler ε_S des Stichproben-Mittelwerts mit der gegebenen Konfidenz gegenüber dem (unbekannten) Mittelwert der Verteilung der Zielfunktionswerte, definiert durch $\varepsilon_S = t_{S-1, 1-\alpha/2} \cdot \frac{\sigma_S}{\sqrt{S}}$
- Durchführung weiterer Simulationsläufe, solange μ^* kleiner ist als die Obergrenze des Konfidenzintervalls von μ_S , d. h. $\mu_S + \varepsilon_S > \mu^*$
- Abbruch nach maximal S^{\max} Simulationsläufen, Rückgabe von $\max\{\mu^*; \mu_S\}$ zusammen mit der korrespondierenden Lösung

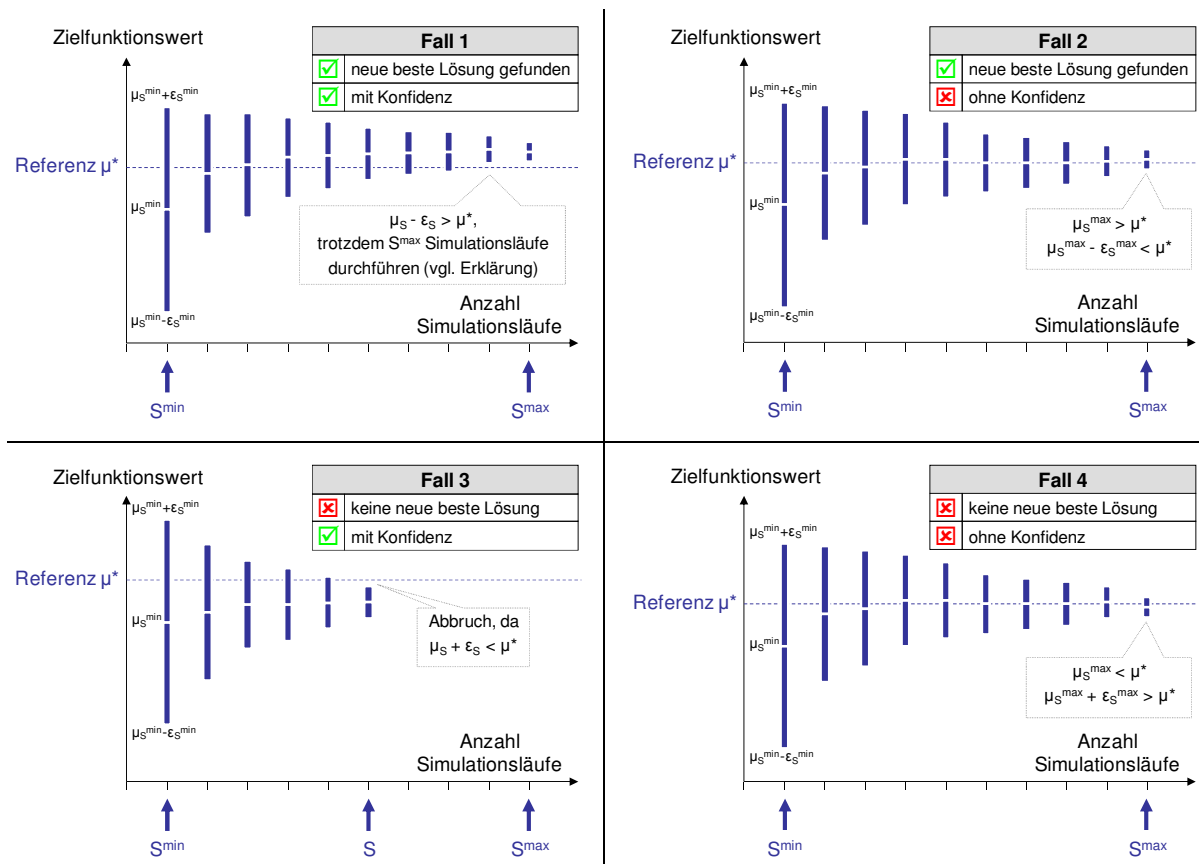


Abbildung 28: Replikationsverlauf unter dem Evaluationskriterium2

Quelle: eigene Darstellung

Beide bisher vorgestellten Entscheidungskriterien eignen sich insbesondere für eine beliebig große Anzahl zu überprüfender Lösungskandidaten. Da für die jeweils zu treffende Entscheidung nur der zu untersuchende Lösungskandidat sowie ein Referenzwert benötigt wird, kann die Optimierung auch mit geringem Aufwand zum Datenaustausch auf mehreren Simulatoren parallelisiert werden.

Ein quantitativer Vergleich der Entscheidungskriterien anhand der später in Kapitel 7.1 skizzierten vereinfachten Simulation des Mobilfunkmarktes zeigt die erwartete Überlegenheit des Evaluationskriterium2. Als Suchalgorithmus sei hierzu der in Kapitel 6.2.1 vorgestellte Algorithmus „Global Random Search“ verwendet, der aufgrund seiner rein zufälligen Lösungsauswahl je Iteration für keine der Prozeduren strukturelle Vor- oder Nachteile bietet.




Abbildung 29: Vergleich der Evaluationskriterien

Quelle: eigene Berechnung und Darstellung

Je Lösungskandidat werden durch das jeweilige Evaluationskriterium gesteuert zwischen $S^{min} = 20$ und $S^{max} = 500$ Replikationen durchgeführt, wobei die beste Lösung im Optimierungsverlauf zur Vergleichbarkeit immer mit der maximalen Anzahl S^{max} an Simulationsläufen repliziert wird. Abbildung 29 zeigt den Verlauf des durchschnittlich besten Zielfunktionswerts aus je 25 unabhängigen Optimierungsläufen entlang der bis dahin benötigten Anzahl Simulationsläufe. Mit einem Simulationsbudget von 50.000 (50k) Zielfunktionsauswertungen ermöglicht das Evaluationskriterium1 durchschnittlich 1.532 Iterationen des Suchalgorithmus (entspricht der Anzahl überprüfter Lösungen), während das Evaluationskriterium2 2.307 Iterationen (ca. 50 % mehr) gestattet. Dies bedeutet aus einem anderen Blickwinkel, dass im ersten Fall durchschnittlich 32,6 Zielfunktionsauswertungen je Lösungskandidat notwendig sind, im zweiten Fall lediglich 21,7. Trotzdem liefert das Evaluationskriterium2 eine durchgängig bessere Lösungsgüte (d. h. höhere Zielfunktionswerte), was die Schlussfolgerung erlaubt, dass nicht signifikant gute Lösungen falsch eingeschätzt werden. Der Fehler erster Art zeigt sich also nicht bedeutsam. Im Folgenden wird deshalb ausschließlich das Evaluationskriterium2 zur Bestimmung der notwendigen Anzahl Replikationen im Rahmen der verschiedenen gezeigten Optimierungen verwendet.

Die bisher diskutierten Evaluationskriterien ermöglichen eine recht einfache Implementierung, da von der jeweils besten Lösung lediglich der durchschnittliche Stichproben-Mittelwert μ^* zwischengespeichert und zum Vergleich herangezogen werden muss. Besteht hingegen die Möglichkeit, die gesamte Stichprobe der für ein θ^* berechneten Zielfunktionswerte $\phi_{i=1 \dots S^{max}}^*(\theta^*, \mathbf{y})$ zu speichern, ergeben sich erweiterte und potenziell noch präzisere Möglichkeiten zur Prüfung, welche der betrachteten Lösungen besser ist. Neben der Zwischenspeicherung muss aber auch ein erhöhter Aufwand für die Prüfung dieser komplexeren Evaluationskriterien bei der Implementierung und der Durchführung der Optimierung berücksichtigt werden.

Das *Evaluationskriterium3* verwendet diese zusätzlichen Daten für eine Paarung der einzelnen Stichprobenwerte aus bisher bester und aktuell überprüfter Lösung. Die Differenz dieser gepaarten Werte kann als Zufallsvariable betrachtet werden, für die mit einem t-Test unter Normalverteilungsannahme überprüft wird, ob deren Erwartungswert von null verschieden ist (vgl. [Spall 2003], Anhang B.2). Ein struktureller Nachteil dieses Kriteriums ist jedoch, dass für die Prüfung aufgrund der Zuordnung von Paarungen nur eine identische Anzahl an Stichprobenwerten herangezogen werden kann. Solange die Anzahl der aus der aktuellen Lösung gezogenen Stichproben $S < S^{max}$ ist, bleiben folglich $S^{max} - S$ Replikationen der bisher besten Lösung unberücksichtigt.

Hingegen kann das *Evaluationskriterium4* explizit mit einer unterschiedlichen Mächtigkeit der Stichproben im Vergleich zwischen aktuell überprüfter und bisher bester Lösung umgehen. Zusätzlich kann hierbei die dem t-Test zugrunde liegende approximative Annahme einer Normalverteilung der Stichproben-Mittelwerte mit identischer Varianz relaxiert werden. Das vorgestellte Kriterium basiert auf dem bekannten Wilcoxon-Rangsummentest (vgl. z. B. [Lehmann 2006], Kap. 1, [Büning und Trenkler 1994], Kap. 5.4.2 oder [Gibbons und Chakraborti 2003], Kap. 8.2). Die Anwendung dieses Tests folgt Überlegungen von [Gibbons und Chakraborti 2003] (Kap. 6.1), wonach die Problemstellung allgemein betrachtet einen Vergleich der Lage zweier nicht notwendigerweise gleich großer Grundgesamtheiten X und Y mit nicht näher spezifizierten (nichtparametrischen) Verteilungen darstellt. Dafür gibt es in der Statistik dedizierte sogenannte *nichtparametrische Testverfahren*, welche keine Annahme einer parametrischen Verteilung (z. B. der Normalverteilung) der Stichprobenwerte voraussetzen (vgl. [Büning und Trenkler 1994]). Selbst wenn eine parametrische Verteilung zwar asymptotisch angenommen werden kann, ist diese Annahme häufig aufgrund einer relativ kleinen Stichprobenmächtigkeit oder verrauschter Werte zumindest fragwürdig. Nichtparametrische Tests zeigen dann ihre Überlegenheit gegenüber parametrischen Tests wie z. B. dem t-Test (vgl. [Büning und Trenkler 1994], S. 135). Eine mittels dieses Kriteriums durchgeführte Überprüfung soll zeigen, welche der betrachteten Grundgesamtheiten *stochastisch größer* ist als die andere, d. h. für den Nachweis von $X > Y$ muss gezeigt werden, dass $P(X > Y) > P(X < Y)$ gilt (vgl. [Gibbons und Chakraborti 2003], S. 234). In ihrem Kapitel 8 zeigen [Gibbons und Chakraborti 2003] verschiedene solcher Tests für den Vergleich der Lage zweier Grundgesamtheiten anhand von Stichproben, von denen der Wilcoxon-Rangsummentest von vielen Statistikern als der beste nichtparametrische Test angesehen wird (S. 279). Die Grundidee des Tests ist einfach: Beide Stichproben werden zu einer gemeinsamen Stichprobe zusammengefasst und nach Zielfunktionswerten geordnet. Die hieraus resultierenden Rangziffern der einzelnen Stichprobenelemente werden je Stich-

probe summiert. Eine bessere Lösung wird dann durch eine niedrigere Rangsummenzahl identifiziert. Aufgrund der Verwendung von Rangziffern anstatt konkreter Zielfunktionswerte ist der Wilcoxon-Rangsummentest ein sehr robustes Werkzeug, da ein guter Teil des potenziell vorhandenen Rauschens bereits durch die Rangbildung selbst eliminiert wird. Lediglich Rauschen, das in der gemeinsamen geordneten Stichprobe zu einer Vertauschung von Rängen führt, korrumpiert noch das Ergebnis des Tests. Bereits im Verlauf der Evaluation der aktuell überprüften Lösung, also solange die zu vergleichenden Stichproben eine unterschiedliche Mächtigkeit haben, kann wie in [Gibbons und Chakraborti 2003] (S. 301 ff.) dargestellt mit dem Wilcoxon-Test überprüft werden, ob eine der Grundgesamtheiten bei der erreichten Mächtigkeit der Stichprobe bereits statistisch signifikant besser ist als die andere Stichprobe. Dann kann gegebenenfalls auf weitere Replikation bis S^{max} verzichtet werden.

Alle speziell für die sequenzielle Optimierung geeigneten Evaluationskriterien lassen ein Charakteristikum der Problemstellung unberücksichtigt, das [Hong und Nelson 2007] aufgreifen: Lösungskandidaten, die zu Beginn des Optimierungsablaufs erzeugt werden, sind zwar bei ihrer Evaluation potenziell nur mit hohem Replikationsaufwand von vorher erzeugten Lösungen abzugrenzen. Im weiteren Verlauf der Optimierung finden sich aber mit hoher Wahrscheinlichkeit weit bessere Lösungen, die den Ausschluss der klar unterlegenen früheren Lösungen leicht ermöglichen. Eine Modifikation der Evaluationskriterien, die diesen Zusammenhang berücksichtigen würde, müsste also im frühen Stadium des Optimierungslaufs eine höhere Unsicherheit bei der Auswahlentscheidung akzeptieren, um die dadurch eingesparten Replikationen für eine intensivere Exploration und Evaluation späterer (potenziell besserer) Lösungen verwenden zu können.

In der Literatur existieren einzelne Ansätze, die strengere Anforderungen an die Vorteilhaftigkeit stellen. Eine neue Lösung muss dort eine definierte Verbesserung bieten, um als neue beste Lösung akzeptiert zu werden. [Spall 2003] (S. 51) formuliert hierzu die „Two-sigma-improvement“-Regel, nach der eine neue Lösung zumindest die alte beste Lösung um zweimal deren Standardabweichung übertreffen muss. Ein solches Vorgehen erscheint aber nur für die Fälle zweckmäßig, in denen der Wechsel zwischen zwei besten Lösungen mit Kosten verbunden ist, z. B., wenn dies Änderungen am realen System wie das Umrüsten von Maschinen nach sich zieht. In allen anderen Fällen gibt es abseits der Berücksichtigung weiterer Faktoren (wie z. B. der Varianz) kaum einen Grund, sich nicht für die Lösung mit dem besten Stichproben-Mittelwert zu entscheiden. Im Folgenden wird deshalb keine definierte Verbesserung vorausgesetzt, gleichwohl würde sich dieser Ansatz in einem geeigneten Kontext problemlos in die später vorgestellten Algorithmen einbeziehen lassen.

5.2. Anwendungsbezogene Einordnung von Standardansätzen

In der Literatur wird häufig als ein zentrales Unterscheidungskriterium zwischen Algorithmen angesehen, ob diese auf einem Lösungsraum mit diskreten oder kontinuierlichen Variablen arbeiten (z. B. bei [Andradottir 1998] und [Olafsson und Kim 2002]). Bei

genauerer Betrachtung stellt man aber fest, dass sich die meisten Verfahren (ggf. mit leichten Modifikationen) sowohl für diskrete, diskret-kontinuierliche (Raum ist zwar kontinuierlich, aber nur diskrete Punkte sind als Lösungen erlaubt, d. h., während des Optimierungsverlaufs kann die Diskretheit relaxiert werden) als auch kontinuierliche Optimierungsprobleme sowie für gemischte Varianten in der praktischen Anwendung eignen. Häufig sind lediglich die ggf. nachgewiesenen theoretischen Konvergenzeigenschaften nur für einen diskreten bzw. kontinuierlichen Lösungsraum gültig, was aber keine direkte Relevanz für die praktische Leistung des Algorithmus haben muss.

Beispielsweise kann der eigentliche kontinuierlich operierende SPSA (siehe Kap. 5.2.2) durch eine Reparatur (z. B. durch Rundung) der finalen Lösung auch für diskret-kontinuierliche Problemstellungen verwendet werden und selbst auf rein diskreten Problemen ist er anwendbar, wenn man die Schrittweiten so wählt, dass nur diskrete Lösungen erreicht werden (vgl. [Spall 2003], S. 195). Verschiedene Autoren kommen deshalb auch zu unterschiedlichen Sichtweisen, während [Hong und Nelson 2006] den SPSA als diskret klassifizieren, beschreibt [Spall 2003] (Kap. 7) die Grundversion des Algorithmus mit kontinuierlichen Variablen. Ebenso kann bei der eigentlich diskreten Tabusuche (siehe Kap. 5.2.3.1) im kontinuierlichen Fall durch die Bildung geeigneter Umgebungen um die Lösungen der Tabuliste erreicht werden, dass ein Schritt in diese Umgebungsbereiche für tabu erklärt wird. Für das normalerweise diskrete Simulated Annealing (siehe Kap. 5.2.3.1) zeigen [Henderson et al. 2003] ebenfalls kontinuierliche Anwendungen. Evolutionäre Algorithmen schließlich werden von [Spall 2003] (S. 232) für alle diskutierten Variablentypen als geeignet angesehen. Aufgrund dieser gezeigten Unschärfen sei im Folgenden darauf verzichtet, zwischen diskreten und kontinuierlichen Algorithmen explizit zu unterscheiden.

Allgemein sei also angenommen, dass sich alle gezeigten Algorithmen grundsätzlich auf alle betrachteten Problemstellungen anwenden lassen, wobei gegebenenfalls Modifikationen notwendig werden (vgl. auch Tabelle 7): Im kontinuierlichen Lösungsraum bedeutet dies für die Anwendung eines diskreten Algorithmus, dass die Werte der Optimierungsvariablen hinreichend feingranular diskret unterteilt (klassiert) werden müssen. Umgekehrt kann ein kontinuierlicher Algorithmus im diskreten Lösungsraum operieren, wenn sichergestellt ist, dass nur zulässige diskrete Lösungen betrachtet werden oder kontinuierliche Lösungswerte durch Rundung oder anderweitige Projektion (vgl. z. B. [Hill 2005]) auf einen zugelassenen diskreten Wert im Lösungsraum überführt werden. Je nach verwendetem Algorithmus und Rasterabstand der diskreten Lösungen kann speziell die letztgenannte Variante aber problematisch sein und z. B. das Steckenbleiben einer Lokalsuche auf einer einzelnen diskreten Lösung hervorrufen.

		Algorithmus	
		kontinuierlich	diskret
Lösungs- raum/ Problem- stellung	kontinuierlich	✓ Ohne Modifikation anwendbar	- Feingranulare Unterteilung (Klassierung) des Lösungsraumes
	diskret	- Sicherstellung, dass Algorithmus nur zulässige (diskrete) Lösungen betrachtet - Rundung/Projektion kontinuierlicher Werte	✓ Ohne Modifikation anwendbar

Tabelle 7: Anwendung kontinuierlicher bzw. diskreter Algorithmen

Quelle: eigene Analyse

Ebenfalls wenig geeignet erscheint die Einteilung von Algorithmen anhand ihrer theoretischen Konvergenzeigenschaften bzw. Konvergenzgeschwindigkeiten. Diese sind zwar für einzelne Algorithmen selbst im Fall stochastischer Zielfunktionsauswertungen durchaus nachweisbar, wie z. B. für den SPSP (vgl. [Spall 2003], Kap. 7.3) oder für den COMPASS (vgl. [Hong und Nelson 2006]), erlauben jedoch keine direkten Schlüsse auf deren praktische Anwendung, insbesondere auch im Vergleich zu nicht theoretisch konvergenten Heuristiken (vgl. [Olafsson und Kim 2002] sowie [Spall et al. 2006]). Vielmehr hängt es von dem zu lösenden Problem ab, ob und wie schnell der verwendete Algorithmus eine gute Lösung findet.

Das „No free lunch“-Theorem (der Begriff wurde geprägt von [Wolpert und Macready 1997]) besagt, dass auf der Menge aller möglichen zu optimierenden Problemstellungen alle Algorithmen im Durchschnitt gleich gut sind. Ein vorteilhafter Algorithmus muss also gewisse Annahmen hinsichtlich der Problemstruktur ausnutzen. Andernfalls kann es passieren (wie [Wolpert und Macready 1997] zeigen), dass ein auf einer eingeschränkten Menge an Problemstellungen getesteter und für überdurchschnittlich gut befundener Algorithmus auf allen anderen Problemstellungen im Schnitt nachweislich eine schlechtere Leistung erzielt als eine einfache zufällige Suche.

Im Sinne des „No free lunch“-Theorems lassen sich Algorithmen folglich in einer vom Autor entwickelten Klassifizierung danach einteilen, auf welchen Annahmen über den Raum der Zielfunktionsauswertungen sie basieren. Diese Annahme kann (1) aus der Unterstellung eines näherungsweise (funktionalen) Zusammenhangs zwischen Optimierungsvariablen und Zielfunktionsauswertung bestehen. In diesem Fall kann eine Optimierung auf deterministischen Ersatzmodellen (siehe Kap. 5.2.1) diese Problemstruktur bei der strukturellen Spezifikation des Ersatzmodells berücksichtigen. Solche Ansätze eignen sich z. B. für physikalische Systeme, bei denen ein inhärenter funktionaler Zusammenhang zwischen Input und Output besteht, die Messung des Outputs aber mit einem stochastischen Messfehler behaftet ist. Eher ungeeignet ist der Ansatz hingegen bei komplexen stochastischen Systemen, die keinen funktionalen Zusammenhang abbilden. Weniger restriktiv ist (2) die Annahme, dass der Raum der Zielfunktionsauswertungen zumindest im lokalen Kontext häufig monotone Bereiche aufweist. In solchen Fällen kann eine Optimierung mit

Gradientenverfahren (siehe Kap. 5.2.2) gezielt dazu eingesetzt werden, entlang des Anstiegs dieser monotonen Bereiche eine lokale Verbesserung zu erzielen. Sind solche Annahmen nicht problemadäquat möglich, wird aber (3) zumindest ein weitgehend korrelierter Zusammenhang zwischen den Zielfunktionsauswertungen verschiedener benachbarter Lösungen erwartet, so können Metaheuristiken (siehe Kap. 5.2.3) zur Optimierung eingesetzt werden. Ohne jegliche problemspezifischen Annahmen bleibt (4) nur die Optimierung durch Anwendung einer zufälligen Suche (siehe Kap. 5.2.4).

Bei der folgenden Beschreibung der Optimierungsverfahren werden die Bezeichnungen *aktuelle Lösung*, *Verlaufslösung* und *beste Lösung* verwendet, welche vorab kurz eingeführt seien. Die aktuelle Lösung ist diejenige Belegung der Optimierungsvariablen, für welche zu einem bestimmten Zeitpunkt durch den Ablauf der Simulation ein Zielfunktionswert ermittelt wird. Sowohl bei Gradientenverfahren als auch bei metaheuristischen Punkt-zu-Punkt-Verfahren findet man das Konzept einer Verlaufslösung, diese bezieht sich auf die Ausgangslösung für den iterativ nächsten Schritt der Optimierung, z. B. bei Gradientenverfahren der Punkt, für den der Gradient approximiert werden soll. Die beste Lösung ist schließlich die beste im Optimierungsverlauf bis dato gefundene Lösung, welche bei einem Abbruch der Optimierung auch das Ergebnis der Optimierung darstellen würde.

5.2.1. Optimierung auf Ersatzmodellen

Allen Ansätzen dieser Kategorie ist gemein, dass aus stochastischen Optimierungsmodellen deterministische Ersatzmodelle (auch Metamodelle genannt) abgeleitet werden, die dann mit geeigneten Methoden der klassischen, deterministischen Optimierung gelöst werden können. Abbildung 30 zeigt den typischen Ablauf, bei dem das Ersatzmodell durch Simulationsläufe mit verschiedenen Ausprägungen der Optimierungsvariablen auf eine gewünschte Übereinstimmung mit dem Simulationsmodell hin kalibriert wird.

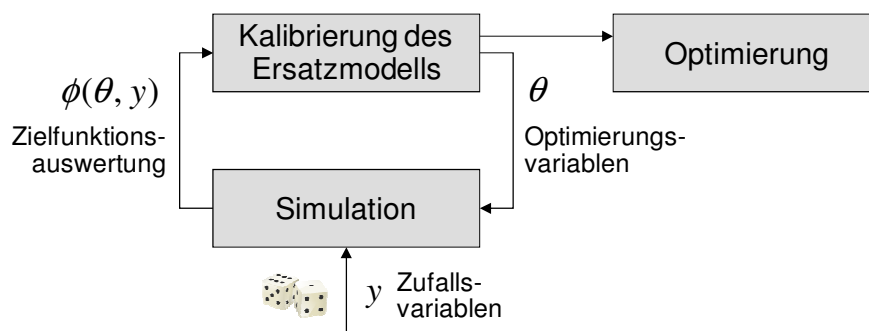


Abbildung 30: Schematischer Ablauf einer Optimierung auf Ersatzmodellen

Quelle: eigene Darstellung

Bei der *Response Surface Method* (RSM) wird eine Regression durchgeführt, die einen angenommenen funktionalen Zusammenhang anhand der Auswertung einer begrenzten Anzahl von Lösungskandidaten näher bestimmt. Die Optimierung erfolgt auf diesem deterministischen Ersatzmodell (vgl. z. B. [Gosavi 2003], Kap. 6) unter Anwendung eines je

nach Funktion geeigneten Verfahrens der deterministischen Optimierung. Die Regression kann hierbei auch stückweise durch eine Aufteilung in Teilbereiche des Lösungsraumes erfolgen, für die jeweils unterschiedliche Annahmen hinsichtlich des funktionalen Zusammenhangs getroffen werden. Generell gilt aber die Einschränkung, dass für diesen Algorithmus eine Annahme zum funktionalen Zusammenhang notwendig ist, was bei Problemen der SBO häufig nicht möglich ist.

Die deutlich flexiblere Optimierung auf Basis *Neuronaler Netze* funktioniert vergleichbar zur RSM, allerdings wird hier ein Neuronales Netz anstelle einer Funktion mithilfe der ausgewerteten Lösungen kalibriert (vgl. z. B. [Gosavi 2003], Kap. 6). Dieses Neuronale Netz wird dann als Ersatzmodell für die Optimierung verwendet. Für diesen Ansatz ist keine Definition eines funktionalen Zusammenhangs notwendig, stattdessen aber das Design des Netzwerks.

Um im stochastischen Kontext verwertbare Zielfunktionswerte für die ausgewählten Lösungskandidaten zu erhalten, wird üblicherweise ein Mittelwert über mehreren Replikationen der Simulation gebildet. Eine Alternative zu dieser ressourcenintensiven Technik stellen [dos Santos und dos Santos 2009] vor: Anstatt mehrere Replikationen auf eine Lösung zu verwenden, fügen die Autoren zwischen den betrachteten Lösungen zusätzliche Zwischenlösungen ein und führen für jede (Zwischen-)Lösung nur eine einzelne Zielfunktionsauswertung durch. Der repräsentative Zielfunktionswert einer (Zwischen-)Lösung wird durch einen exponentiell gewichteten gleitenden Durchschnitt über mehreren benachbarten Lösungen berechnet. So kann bei einem identischen Budget an Simulationen eine deutlich feingranularere Abdeckung des Lösungsraumes als Grundlage für die Regression verwendet werden.

Die *Sample-Path-Optimierung* (vgl. z. B. [Andradottir 1998] oder [Fu 2002]) verwendet anstelle der stochastischen Simulation $\phi(\theta, \mathbf{y})$ deren deterministisches Äquivalent $\phi(\theta, \bar{\mathbf{y}})$ für n zufällig oder strukturiert gewählte Wertebelegungen $\bar{\mathbf{y}}$ der Zufallsvariablen (auch Samples oder Szenarien genannt). Auf diese deterministischen Funktionen lassen sich abermals klassische Algorithmen der deterministischen Optimierung anwenden. Eine Zusammenführung der Menge an Samples für eine Lösung des stochastischen Ausgangsproblems kann durch Mittelwertbildung der auf den einzelnen Funktionen erzielten Optimierungslösungen $(\sum_{i=1 \dots n} \theta_i^*)/n$ erfolgen, oder bei mehrfachem Auftreten identischer Lösungen durch Auswahl der Optimierungslösung θ^* , die für die größte Anzahl an Samples optimal ist. Alternativ werden bei der *Sample Average Approximation* (vgl. [Kleywegt et al. 2001] oder [Shapiro 2003]) vergleichbar mit der Response Surface Method über den gesamten Definitionsbereich der Optimierungsvariablen für feingranular gewählte repräsentative Werte θ die Zielfunktionsauswertungen der Samples gemittelt $(\sum_{i=1 \dots n} \phi_i(\theta, \bar{\mathbf{y}}_i))/n$. Eine auf diesen diskreten Punkten approximierte deterministische Funktion kann anschließend mit klassischen Methoden optimiert werden.

5.2.2. Optimierung mit Gradientenverfahren

Zur Optimierung werden häufig Gradientenverfahren eingesetzt, bei denen (wie in Abbildung 31 dargestellt) iterativ von einer Verlaufslösung die Richtung der bestmöglichen

Verbesserung gesucht und in diese Richtung ein Schritt zu einer neuen Verlaufslösung durchgeführt wird. Da bei der hier betrachteten SBO die Richtung der bestmöglichen Verbesserung in Ermangelung einer explizit spezifizierten Zielfunktion nicht direkt funktional abgeleitet werden kann, sind Verfahren zur sogenannten *stochastischen Approximation* dieses Gradienten auf Basis lediglich von Simulationsauswertungen notwendig. Durch eine Reduktion der Schrittweite im Optimierungsverlauf kann eine asymptotische Konvergenz eines solchen Verfahrens hin zu einer lokal optimalen Lösung erreicht werden.

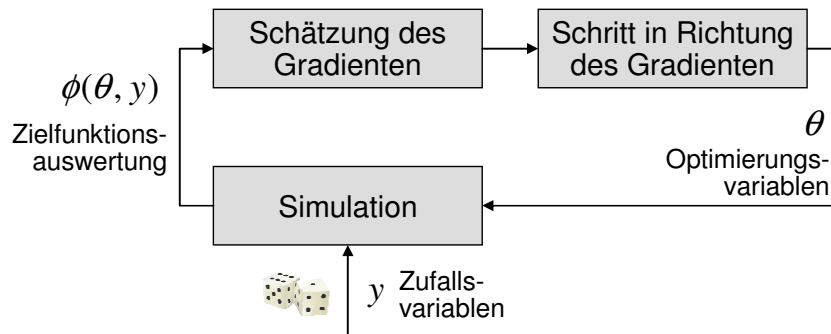


Abbildung 31: Schematischer Ablauf einer Optimierung mit Gradientenverfahren

Quelle: eigene Darstellung

Bei der *Finite Differences Stochastic Approximation* (FDSA, vgl. z. B. [Spall 2003], Kap. 6) wird bei einer Verlaufslösung für jede Optimierungsvariable einzeln ein Gradient dadurch approximiert, dass der Wert dieser Variablen in der Verlaufslösung plus bzw. minus eine bestimmte Abweichung gewählt wird unter Beibehaltung der Werte der übrigen Variablen. An den so konstruierten Lösungskandidaten wird jeweils eine einzelne Simulationsauswertung durchgeführt und anhand der Differenz dieser beiden Lösungen ein Gradient gebildet. Dieses Verfahren erfordert somit für die Schätzung des Gradienten in einer Verlaufslösung (für jede Iteration) bei n Optimierungsvariablen $2n$ Simulationsauswertungen und ist damit vergleichsweise ressourcenintensiv.

Die *Simultaneous Perturbation Stochastic Approximation* (SPSA, vgl. [Spall 2003]), Kap. 7) hingegen benötigt lediglich zwei Simulationsauswertungen je Iteration, da der Gradient über einem gemeinsamen Intervall für alle Optimierungsvariablen approximiert wird. Dieser Effizienzgewinn wird aber mit einer gröberen Schätzung des Gradienten bezahlt. Über den Optimierungsverlauf hinweg gleichen sich die so erkaufte ungenaueren Schritte aber aus, sodass der SPSA häufig eine zum FDSA vergleichbare Leistung mit deutlich weniger Zielfunktionsauswertungen (oder äquivalent Simulationen) erreicht. Die formale Spezifikation einer Implementierung des Algorithmus SPSA findet sich in Kapitel 6.2.3 der vorliegenden Arbeit.

Kritisch für den erfolgreichen Einsatz der beiden vorgestellten Gradientenansätze ist, dass sowohl die Größe der Abweichung von der aktuellen Verlaufslösung für die Bildung des Gradienten als auch die Schrittweite hin zu einer neuen Verlaufslösung a priori problemadäquat festgelegt werden müssen. Sind diese Parameterwerte zu groß gewählt, bildet der Gradient die lokale Struktur des Lösungsraumes nicht mehr adäquat ab, was bestenfalls in einer zufälligen Suche mündet. Bei zu kleinen Parameterwerten hingegen konvergiert der

Algorithmus nur mühsam (z. B. bei großen ebenen Flächen im Lösungsraum) oder speziell im Falle eines Lösungsraumes mit vielen lokalen Optima potenziell weit abseits des globalen Optimums. Falls vorab keine hinreichenden Kenntnisse über die Struktur des Lösungsraumes vorliegen, sind Testläufe der Gradientenverfahren mit verschiedenen Parametereinstellungen unumgänglich.

Im Gegensatz zu den im Folgenden vorgestellten Metaheuristiken sind die auf der stochastischen Approximation basierenden Optimierungsverfahren bezüglich ihres Designs dediziert für stochastische (verrauschte) Zielfunktionsauswertungen geeignet. Das bedeutet, dass die jeweils betrachtete Verlaufslösung nicht exakt evaluiert werden muss, da der Algorithmus gegenüber der Unsicherheit in der Bewertung des Lösungskandidaten robust ist und lediglich auf die Konvergenz hin zu einer guten Lösung abzielt.

Zu beachten ist aber, dass Gradientenverfahren generell nur bei Problemen funktionieren, die zumindest im lokalen Kontext eine gewisse Stetigkeit aufweisen, da genau diese Eigenschaft bei der Gradientenbildung und dem Schritt in Richtung des Gradienten ausgenutzt wird.

5.2.3. Optimierung mit Metaheuristiken

Die Optimierung mit Metaheuristiken umfasst ein breites Feld heuristischer (nicht exakter) Lösungsverfahren, die keine speziellen problemspezifischen Annahmen voraussetzen (vgl. Abbildung 32). Strukturbedingt ist hierbei gegenüber den gezeigten gradientenbasierten Verfahren eine höhere Anzahl an Evaluationen im Optimierungsverlauf notwendig, da Lösungen einzeln und nicht im Kontext der Umgebung anderer Lösungen betrachtet werden. Zur Identifikation guter Lösungen ist eine eingehende Evaluation der einzelnen Lösungskandidaten notwendig, um das stochastische Rauschen dieser Lösungen problemadäquat zu begrenzen.

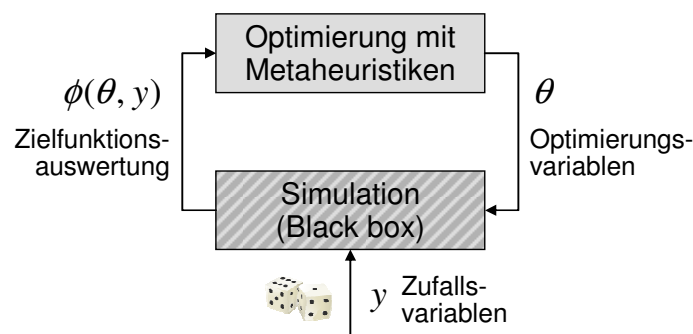


Abbildung 32: Schematischer Ablauf einer Optimierung mit Metaheuristiken
Quelle: eigene Darstellung

Die folgenden metaheuristischen Verfahren werden anhand des Kriteriums eingeordnet, welche Informationen bei der Generierung neuer Lösungskandidaten, der sogenannten *Exploration*, einbezogen werden.

5.2.3.1. Punkt-zu-Punkt-Verfahren

Punkt-zu-Punkt-Optimierungsverfahren (vgl. [Olafsson 2006]) entwickeln eine Verlaufslösung im Lösungsraum sukzessive weiter. Die Balance besteht hierbei darin, neben effektiven Methoden zur Intensivierung auch die Diversifikation nicht zu vernachlässigen, üblicherweise durch die (bedingte) Akzeptanz einer Verschlechterung in der Verlaufslösung zum Ausbruch aus lokalen Optima. Kernelement eines solchen Verfahrens ist die Definition einer Nachbarschaft, welche die Menge der in der nächsten Iteration direkt erreichbaren Lösungskandidaten definiert und somit den Umfang der möglichen Schritte lokal begrenzt.

Das aus der deterministischen Optimierung bekannte Verfahren *Simulated Annealing* (vgl. [Henderson et al. 2003] für einen ausführlichen Überblick) überprüft iterativ einen zufälligen Lösungskandidaten aus der Nachbarschaft der aktuellen Lösung. Ist diese Nachbarlösung besser als die bisherige Lösung, so ersetzt sie die aktuelle Verlaufslösung in der darauffolgenden Iteration. Falls die Nachbarlösung schlechter ist, wird sie mit einer gewissen Wahrscheinlichkeit trotzdem als aktuelle Lösung akzeptiert. Diese Wahrscheinlichkeit hängt von der Differenz der Bewertung der beiden Lösungen sowie von der Höhe einer angenommenen Temperatur ab, welche im Optimierungsverlauf sukzessive abkühlt und so die Konvergenz in einer besten Lösung ermöglicht. Im Kontext einer Optimierung mit stochastischer Zielfunktion sehen verschiedene Autoren jedoch von dieser Abkühlung ab und verwenden eine konstante Temperatur. [Alrefaei und Andradottir 1999] leiten die Akzeptanzwahrscheinlichkeit nur noch aus der Differenz der beiden Lösungsbewertungen ab, was die Konvergenz des Algorithmus in einer Lösung verhindern soll. Vielmehr wird diejenige Lösung, die im Laufe der Optimierung am häufigsten aufgesucht wurde (oder alternativ die Lösung mit den durchschnittlich besten Bewertungen) als beste gefundene Lösung deklariert. [Alkhamis und Ahmed 2004] steuern die Akzeptanzwahrscheinlichkeit zusätzlich anhand der statistischen Signifikanz der Differenz beider Lösungen bei mehreren Replikationen, wobei wiederum die am häufigsten aufgesuchte Lösung die beste gefundene Lösung darstellt.

Bei der *Tabu-Suche* (vgl. [Gendreau 2003] für eine umfassende Einführung) wird ebenfalls eine zu definierende Nachbarschaft der Verlaufslösung nach der dort besten Lösung durchsucht. Diese Lösung wird zur neuen Verlaufslösung, selbst wenn damit eine Verschlechterung einhergeht. Der vollzogene Schritt wird dann für eine gewisse Anzahl Iterationen gesperrt („tabu“ gesetzt, daher die Bezeichnung des Algorithmus), bis eine Verbesserung der Verlaufslösung erzielt wird. Die Tabuliste dieser verbotenen Schritte muss hierbei geeignet modelliert werden, z. B. kann ein enthaltener Schritt die Veränderung einer bestimmten Menge an Optimierungsvariablen darstellen. Bei der stochastischen Optimierung ist es im Gegensatz zum deterministischen Fall nicht so einfach zu entscheiden, welche Lösung der Nachbarschaft die beste Lösung darstellt. Dazu entwickeln [Costa und Silver 1998] Entscheidungskriterien, die anhand mehrfacher Replikationen und darauf angewendeter statistischer Tests (wie dem t-Test und dem Wilcoxon-Test) verschiedene Lösungen vergleichen. Im Gegensatz zu den Evaluationskriterien aus Kapitel 5.1.2 verwenden die Autoren dort diese Tests jedoch nicht, um die notwendige Anzahl an Replikationen zu bestimmen, sondern um bei einer fest vorgegebenen Anzahl an Replikationen lediglich zu entscheiden, ob eine bestimmte Lösung besser ist als eine andere Lösung.

5.2.3.2. Mengenbasierte Verfahren

Mengenbasierte Verfahren eignen sich besonders gut für die SBO mit stochastischen Zielfunktionsauswertungen, da sich extreme Stichprobenwerte bei diesem Ansatz nicht drastisch auswirken können (vgl. [Nissen und Propach 1998]). Bei den Punkt-zu-Punkt-Verfahren hingegen besteht generell die Problematik, dass eine stark überschätzte Lösung nur schwerlich wieder verlassen werden kann. Mengenbasierte Verfahren beziehen jedoch neben der Umgebung dieser Lösung inhärent auch die Umgebungen anderer Lösungen in den weiteren Optimierungsverlauf mit ein. Außerdem spielt hier der präzise ermittelte Wert der Zielfunktion keine dominierende Rolle, da er häufig lediglich für die Ordnung der Lösungskandidaten benötigt wird.

Der *Nelder-Mead-Simplex-Algorithmus* konstruiert ein n -dimensionales Polytop (auch Simplex genannt, daher der Name des Algorithmus), an dessen $n+1$ Ecken Zielfunktionsauswertungen durchgeführt werden (vgl. [Spall 2003], Kap. 2.4). In jeder Iteration wird dem Polytop ein neuer Punkt hinzugefügt und dafür der schlechteste Punkt eliminiert. Im Optimierungsverlauf wird das Polytop immer kleiner und umschließt den Bereich, in dem das so ermittelte Optimum liegen soll. Verschiedene Autoren äußern aber die Ansicht, dass dieser Algorithmus nur bedingt für höherdimensionale Problemstellungen geeignet ist (siehe [Han und Neumann 2006] für einige Referenzen). Offen bleibt, ob sich diese auf spezielle deterministische Zielfunktionen bezogenen Erkenntnisse auch auf die stochastische SBO verallgemeinern lassen.

Deterministische *Branch-and-bound*-Verfahren unterteilen den Lösungsraum iterativ in Teilbäume und bestimmen untere bzw. obere Schranken für diese Bereiche. Hierdurch sollen Mengen von Lösungskandidaten frühzeitig im Optimierungsverlauf als nicht optimal identifiziert und von der detaillierten Untersuchung ausgeschlossen werden, bis schließlich nur noch die optimale Lösung übrig bleibt. Für stochastische Problemstellungen ist die Bestimmung solcher Schranken in der Regel nicht exakt möglich, vielmehr stehen lediglich Schätzungen anhand wiederholter Zielfunktionsauswertungen zur Verfügung. [Norkin et al. 1998] zeigen für diesen entscheidenden Aspekt, wie man die Schranken herleiten und damit eine effektive Begrenzung des Suchbaums durchführen kann.

Der *Nested-Partitions-Algorithmus* vollzieht eine iterativ verfeinerte systematische Partitionierung vielversprechender Regionen im Lösungsraum (vgl. [Olafsson 2004], [Shi und Olafsson 2000] und [Lin und Lee 2006]). Ein Rückschritt zur übergeordneten Region erfolgt, falls sich die verfeinerte Partition bei eingehender Untersuchung nicht als vielversprechend herausstellt. Die Bewertung der Partitionen erfolgt anhand der Auswertung zufällig gewählter Lösungskandidaten innerhalb dieser Regionen, beispielsweise durch die beste dort vorgefundene Lösung. Die Lösung mit dem besten Stichproben-Mittelwert oder die am häufigsten betrachtete Lösung wird abschließend als die beste gefundene Lösung angesehen. Dies kann bereits die Lösung sein, welche erreicht ist, wenn die vielversprechende Partition bei der maximalen Partitionierungstiefe erstmals nur aus einer Lösung besteht. Wie verschiedene Autoren zeigen, lassen sich in einen so strukturierten Algorithmus auch lokale Verbesserungs- (vgl. [Pichitlamken und Nelson 2003]) und statistische Auswahlverfahren (vgl. [Olafsson 1999], [Olafsson 2004] und [Pichitlamken und Nelson 2003]) integrieren.

Scatter Search (vgl. [Laguna und Marti 2003] für eine umfassende Einführung) ist ein Algorithmus, der eine zufällige Menge von Referenzlösungen durch paarweise Kombination iterativ optimiert. Diese Kombination geschieht z. B. durch gewichtete Linearkombination (Inter- und Extrapolation) der Lösungskomponenten. Die insgesamt besten Lösungen bilden davon ausgehend wiederum die Ausgangsmenge der folgenden Iteration. Durch eine integrierte Verbesserungsmethode kann die Suche zusätzlich lokal intensiviert werden. Die strategische Behandlung der Menge von Referenzlösungen ist hierbei von entscheidender Bedeutung, um die Diversifikation des Algorithmus zu steuern.

Evolutionäre Algorithmen (vgl. [Eiben und Smith 2007]) entwickeln eine Population von Lösungen über Iterationen hinweg mit den an die biologische Evolution angelehnten Operatoren Mutation, Kreuzung und Selektion. Lösungen werden anhand der in diesem Kontext sogenannten „Fitness“ bewertet, wobei bessere Lösungen mit einer höheren Wahrscheinlichkeit für die Reproduktion im Rahmen der Mutation oder Kreuzung ausgewählt werden. Für die nachfolgende Generation werden aus der Menge der reproduzierten Lösungen die Besten selektiert, zusätzlich werden besonders gute (sogenannte elitäre) Lösungen aus der Ausgangspopulation übernommen. Der in Kapitel 6.2.4 formal dargestellte Algorithmus NELS ist ein Beispiel für einen evolutionären Algorithmus.

5.2.4. Optimierung durch zufällige Suche

Der *Global Random Search* ist ein rein punktbasierendes Verfahren (vgl. [Andradóttir 2006]), das keine strukturellen Informationen über den Lösungsraum und insbesondere keine bis dato gewonnenen Informationen des Optimierungsverlaufs verwendet (vgl. [Spall 2003], Kap. 2.2 und 2.3). Stattdessen werden lediglich Punkte über den gesamten Definitionsbereich der Optimierungsvariablen zufällig ausgewählt und evaluiert. Die formale Spezifikation einer Implementierung des Algorithmus findet sich in Kapitel 6.2.1.

5.2.5. Industrielösungen zur Optimierung

Die bisher vorgestellten Optimierungsverfahren stellen den Stand der akademischen Forschung dar. Darauf aufbauend gibt es komplette Optimierungssysteme, die sich der gezeigten Verfahren bedienen und diese in einer praxistauglichen Implementierung zur Anwendung bereitstellen. Teilweise sind diese Optimierungssysteme direkt für den industriellen Einsatz geeignet.

Bei *OptQuest*³¹ handelt es sich um ein kommerzielles Produkt, dessen konkrete Implementierung nicht öffentlich dokumentiert ist und aus der Literatur allenfalls bruchstückhaft rekonstruiert werden kann (für Details siehe auch Kap. 6.2.2). Kernelement dieses Optimierungssystems ist eine metaheuristische Suche, basierend auf dem Scatter-Search-Verfahren. Dabei werden aus einer Menge von Lösungen durch Inter- und Extrapolation anhand eines definierten Schemas und unter Zuhilfenahme einer Tabuliste neue Lösungen generiert und überprüft. Als Vorverarbeitungsschritt kann OptQuest ein Neuronales Netz

³¹ Ein Produkt der Firma OptTek, <http://www.opttek.com>, abgerufen am 15. Dezember 2010.

aufbauen, das bei der eigentlichen Optimierung zur Abschätzung der Qualität einer Lösung dient.

Industrial Strength COMPASS (ISC, vgl. [Xu et al. 2010]) entstammt zwar der akademischen Forschung und verwendet entsprechend fortgeschrittene Verfahren zur Optimierung und Evaluation von Lösungen, trotzdem ist dieses Optimierungssystem für den allgemeinen praktischen Einsatz konzipiert. In drei Phasen verknüpft ISC eine Globalsuche, eine Lokalsuche und eine Säuberung der gefundenen Lösungen. Die Globalsuche verwendet einen evolutionären Algorithmus, um vielversprechende Nischen im Lösungsraum zu identifizieren. Dort wird eine Lokalsuche mit dem COMPASS-Algorithmus aus [Hong und Nelson 2006] durchgeführt. Bei der abschließenden Säuberung der gefundenen Lösungsmenge wird unter statistischen Optimalitätsgesichtspunkten eine Selektion der besten Lösung(en) vorgenommen. Für jede der Phasen sind theoretische Konvergenzeigenschaften bei einem unendlichen Aufwand nachgewiesen. Im praktischen Einsatz erfolgt ein Wechsel zwischen den Phasen jedoch bereits nach endlich vielen Iterationen.

6. Simulationsbasierte Optimierung der Parameter einer agentenbasierten Simulation

Die simulationsbasierte Optimierung hat sich zu einem viel beachteten Forschungsfeld entwickelt. Im Kontext der agentenbasierten Simulation fristet sie jedoch ein Schattendasein, eine grundlegende Aufarbeitung dieses Themenfelds fehlt in der Literatur. Auch anwendungsbezogene Arbeiten sind vergleichsweise selten. Illustriert wird dies durch die Tatsache, dass das Thema Optimierung im umfangreichen Übersichtsartikel von [Heath et al. 2009], der 279 Arbeiten zur agentenbasierten Simulation über einen Zeitraum von zehn Jahren untersucht, nicht ein einziges Mal erwähnt wird.

Vereinzelt werden zwar bei der Kalibrierung von Parametern agentenbasierter Simulationsmodelle einfache Optimierungsansätze zur Anpassung der Simulation an beobachtete empirische Systemcharakteristika verwendet. Hierbei ist der Anspruch aber lediglich, in Fällen, in denen eine manuelle Parameteroptimierung aufgrund der Komplexität und Dimensionalität der Problemstellung nicht praktikabel ist, geeignete Parameterwerte zur Nachbildung eines Systemverlaufs aufzuspüren. Die Optimierung stellt dabei keinen zentralen Anwendungsaspekt dar, sondern dient nur der Automatisierung eines sonst im Rahmen der Modellvalidierung manuell durchgeführten Prozesses.

Darüber hinausgehende Ansätze finden sich in der Literatur nur selten. [Calvez und Hutzler 2006] stellen einen einfachen evolutionären Algorithmus vor, anhand dessen die Parameter einer ABS auf eine zu definierende Zielfunktion hin optimiert werden können. Die Anzahl der je Lösungskandidat verwendeten Replikationen ist statisch vorgegeben, zur Begrenzung des Simulationsaufwands wird dieses Replikationsschema allerdings nur im Abstand einiger Generationen des Algorithmus angewendet, während innerhalb der übrigen Generationen lediglich eine Replikation je Lösungskandidat durchgeführt wird. Den gesamten Optimierungsansatz skizzieren die Autoren anhand einfacher Beispiele.

[Narzisi et al. 2006] optimieren die freien Parameter einer ABS zur Notfallschutzplanung, wobei die Parameter zur näheren Bestimmung der Umwelt und des Agentenverhaltens in Krisensituationen wie z. B. Bombenexplosionen oder Epidemien dienen. Bei dem betrachteten Problem existieren mehrere gegenseitig im Konflikt stehende Zielkriterien (z. B. Minimierung der Opferzahlen, Maximierung der Effizienz im Einsatz von Notfallressourcen), weshalb Standardansätze zur Mehrzieloptimierung verwendet werden.

[Heppenstall et al. 2007] verwenden einen evolutionären Algorithmus, um die Parametrisierung der bereits auf Seite 52 vorgestellten Simulation der Benzinpreisentwicklung so zu optimieren, dass diese eine empirisch beobachtete Preisentwicklung möglichst präzise nachzeichnet. Einbezogen werden sowohl strukturelle Parameter des Gesamtmodells als auch Parameter des individuellen Entscheidungsmodells der Agenten, welche die Preisadjustierungen an den Tankstellen vornehmen. Die Autoren stellen hierbei allerdings fest, dass sich die optimierten Parameterwerte im Vergleich zu initial durch Ausprobieren ermittelten Parameterwerten kaum unterscheiden. Die Optimierung hatte also letztendlich hauptsächlich einen validierenden Charakter.

[Terano 2007] zeigt anhand verschiedener Simulationen sozialer Systeme die Optimierung von Parametern des Entscheidungsmodells der Agenten mit einem evolutionären Algorithmus. Ziel ist der Rückschluss von in der Simulation beobachtetem Makroverhalten auf Effekte im realen System, z. B. bezüglich der Effektivität verschiedener untersuchter Marketingstrategien für Unternehmen. Der Autor geht außer der Berücksichtigung eines potenziell hochdimensionalen Parameterraumes kaum auf die Besonderheiten der ABS ein. Auch die Details, Auswahlkriterien und Eignung des angesprochenen Optimierungsverfahrens werden nicht erörtert.

[Thengvall und Glover 2009] skizzieren den Einsatz einer Verbesserung der kommerziellen Optimierungslösung OptQuest für die Simulation der Raketenabwehr eines Landes. Ziel ist es, eine geeignete Ausstattung mit stationären und mobilen Raketenabwehrsystemen zu erhalten, um im Falle eines Angriffs die Zahl der Überlebenden zu maximieren. Die Autoren beschreiben zwar prinzipiell ihre Erweiterung zum besseren Screening von Lösungen auf der Basis von Data-Mining-Techniken, gehen jedoch nicht auf spezielle Problemcharakteristika und die entsprechende Eignung ihres Ansatzes ein. Zumindest für das betrachtete Problem zeigt die Erweiterung aber einen positiven Einfluss auf Lösungsgeschwindigkeit und -güte.

[Schutte 2010] optimiert mittels eines nicht näher diskutierten evolutionären Algorithmus die Parameter verschiedener Regeln, anhand derer er die Flugbewegungen über dem Flughafen JFK in New York in einem agentenbasierten Simulationsmodell nachzeichnet. Das Studienobjekt ist vom Autor deshalb exemplarisch ausgewählt worden, da zu den Flugbewegungen detaillierte empirische Daten verfügbar sind. Die beabsichtige Deckungsgleichheit zwischen der Simulation und dem realen System wird mit der Optimierung weitgehend erreicht, wenn man von Sondereffekten absieht, die nicht im Modell berücksichtigt wurden.

Wie sich zeigt, verbleibt eine Lücke bei der grundsätzlichen Aufarbeitung der SBO im Rahmen einer ABS. In diesen Bereich stößt die vorliegende Arbeit im Folgenden vor und analysiert grundlegend die allgemeine Problemstellung sowie geeignete Verfahren zur Optimierung einer ABS. Anhand konkreter Beispielp Probleme wird ein Vergleich möglicher Verfahren gezeigt und deren Eignung für generelle Problemstellungen im Kontext der ABS verallgemeinert.

6.1. Spezielle Problemstellung im Kontext einer agentenbasierten Simulation

Die agentenbasierte Simulation repräsentiert (wie in Kap. 3 dargestellt) ein hochgradig komplexes System, geprägt von der Heterogenität der Agenten und deren durch Netzwerkeffekte gegenseitig bedingtem Entscheidungsverhalten. Hieraus resultierende komplexe Wirkungszusammenhänge und emergente Effekte können eine bedeutende Rolle für den Ablauf der Simulation spielen. Der Raum der aus einer solchen Simulation abgeleiteten Zielfunktion ist deshalb in der Regel geprägt von Unstetigkeiten und Sprungstellen, an denen die Entwicklung innerhalb der Simulation signifikant kippt (sogenannten „tipping points“). Der Zielfunktionsraum umfasst aber ebenso häufig große stetige Bereiche, in denen nahe beieinanderliegende Lösungen ähnlich gut sind. Die Anzahl, Ausprägung und Verteilung

von Extrempunkten ist ebenfalls kaum einschätzbar. Aufgrund der komplexen Natur des zugrunde liegenden Systems kann aber allgemein von der Existenz multipler lokaler Extrempunkte ausgegangen werden. Kurz zusammengefasst, die Struktur des Zielfunktionsraumes (die sog. „Oberfläche“ der Zielfunktion) einer ABS ist a priori unklar, bei praktischen Problemstellungen vermutlich zerklüftet und kaum als konvex zu erwarten.

Hinzu kommt, dass durch den stochastischen Charakter der Zielfunktionsauswertungen keine statische Oberfläche ermittelbar ist. Vielmehr erhält man lediglich eine Abschätzung der Oberfläche im Zielfunktionsraum, die sich immer auf konkrete Stichproben der im Modell verwendeten Zufallsvariablen bezieht und die bei einer weiteren Auswertung potenziell wieder anders aussehen kann (vgl. [Stagge 1998]).

Üblicherweise umfasst ein agentenbasiertes Modell eine Vielzahl von Parametern zur Konfiguration des Agentenverhaltens, der Simulationsumgebung und des Simulationsablaufs. Eine hierauf aufbauende SBO ist also mit einem hochdimensionalen Suchraum konfrontiert und muss folglich mit einer großen Anzahl an Variablen zur Abbildung dieser Parameter in der Optimierung umgehen können. Umfasst die ABS z. B. die Entscheidung von Agenten über den Abschluss eines Servicevertrags, so könnten im Rahmen der SBO die für den Anbieter umsatzmaximierenden Preise der angebotenen Servicetarife gesucht werden. Diese Parameter stellen dann die Variablen innerhalb der Optimierung dar, die den Raum der möglichen Lösungen und somit den Suchraum der Optimierung aufspannen. Selbst bei einer vergleichsweise kleinen Problemistanz mit zehn verschiedenen Tarifen, deren Preis sich je zwischen 1 € und 10 € in diskreten Ein-€-Schritten bewegen kann, ergibt sich bereits ein Suchraum von 10^{10} verschiedenen Parameterkombinationen – weit mehr, als mit einer vollständigen Enumeration untersucht werden könnten.

Aus den bisherigen Überlegungen lassen sich also direkt die drei zentralen Charakteristika der Problemstellung ableiten, die ein geeignetes Verfahren zur SBO einer ABS explizit berücksichtigen muss: 1) eine zerklüftete und 2) stochastische Oberfläche der Zielfunktionsauswertungen sowie 3) eine hohe Dimensionalität des Suchraumes.

Abbildung 33 verdeutlicht beispielhaft, welche verschiedenen Strukturen die Oberfläche der Zielfunktionsauswertungen annehmen kann. Als Simulation wird hierbei der in Kapitel 7.1 beschriebene Versuchsaufbau verwendet, dessen Details an dieser Stelle noch keine Rolle für das Verständnis spielen. Die dargestellten Oberflächenkurven ergeben sich aus der Zielfunktion unter Variation eines Parameters über dessen gesamten Definitionsbereich bei gleichzeitiger Festlegung aller anderen Parameter in der Mitte ihrer jeweiligen Definitionsbereiche. Insgesamt stellt dies also nur einen kleinen Ausschnitt des Raumes der Zielfunktionsauswertungen dar. Durch mehrfache Replikation (mindestens 20, maximal 1.000 Replikationen) wurde der Fehler des Stichproben-Mittelwerts der Zielfunktionsauswertungen mit einem Konfidenzniveau von $(1 - \alpha) = 0,98$ auf jeweils < 1.000 begrenzt (bei einer unterstellten Normalverteilung und experimentell ermittelten maximalen Zielfunktionswerten von ca. 200.000).

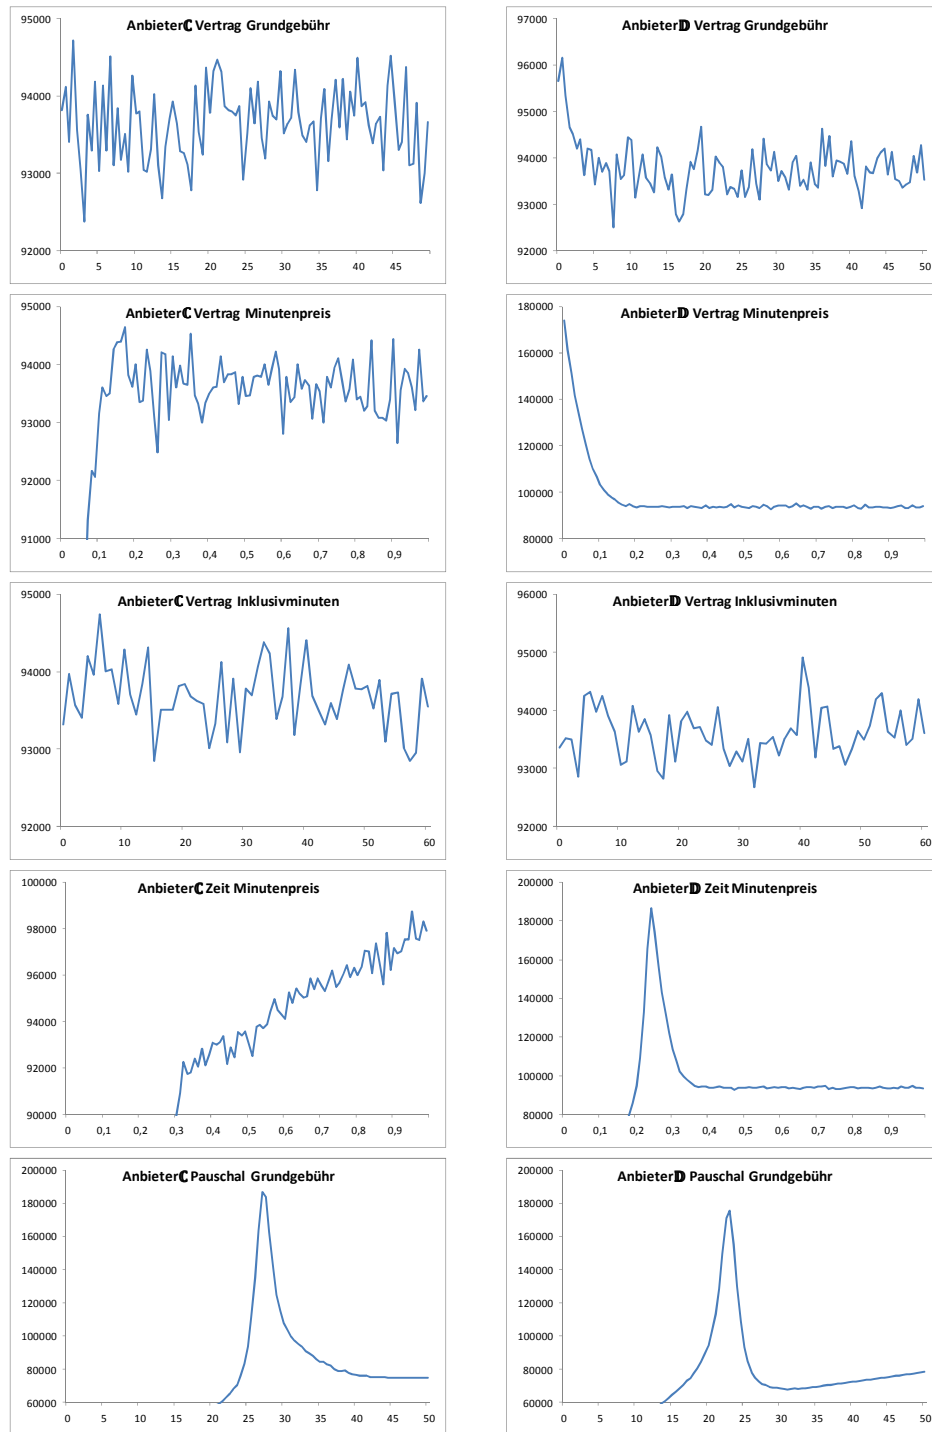


Abbildung 33: Beispielhafte Struktur der Oberfläche der Zielfunktionsauswertungen

Quelle: eigene Berechnung und Darstellung

Augenscheinlich erschließen sich einige der genannten typischen Charakteristika der Problemstellung. Betrachtet man z. B. in Abbildung 33 links oben die Schwankungsbandbreite der Zielfunktionswerte unter Variation des Parameters „AnbieterC Vertrag Grundgebühr“, so erahnt man, dass diese entweder aus komplexen Zusammenhängen in der Simulation resultieren könnten oder aber lediglich ein Ausdruck der verbliebenen stochastischen Unsicherheit von ± 1.000 sind.

Die Komplexität der agentenbasierten Simulation sorgt unter dem Einfluss der Zufallsvariablen für starke stochastische Schwankungen in der Zielfunktionsauswertung, die über den gesamten Lösungsraum betrachtet sehr unterschiedlich profiliert und ausgeprägt sein können. Je nach Lage der untersuchten Lösung können sich völlig unterschiedliche empirische Verteilungen der simulativ ermittelten Zielfunktionswerte ergeben. Abbildung 34 illustriert dies für die 1.000-fache Simulation verschiedener ausgewählter Lösungen abermals unter dem in Kapitel 7.1 beschriebenen Versuchsaufbau. Bei den beobachteten Schwankungen der Zielfunktionswerte handelt es sich um ein stochastisches Rauschen, das aber offensichtlich nicht einer Standardnormalverteilung folgt. Überlegungen, die z. B. bei systematisch auftretenden Messfehlern in stochastischen Systemen oder bei theoretisch orientierten Algorithmenvergleichen ein normalverteiltes Rauschen annehmen, sind folglich bei einer solchen ABS weniger geeignet. Dagegen sind für die SBO einer ABS Verfahren von Vorteil, die ohne die Annahme einer Normalverteilung auskommen.




Abbildung 34: Stochastische Schwankungen der Zielfunktionsauswertung

Quelle: eigene Berechnung und Darstellung

Spätestens bei der Betrachtung dieser Lösungen wird auch deutlich, warum die in Kapitel 5.1.2 diskutierten Evaluationskriterien mit einer variablen Zuordnung der je Lösung verwendeten Anzahl an Replikationen gegenüber einer statischen Anzahl überlegen sind. Je nach empirischer Verteilung der Zielfunktionsauswertungen einer Lösung (und deren daraus abgeleiteter Varianz bzw. Standardabweichung) sind jeweils eine unterschiedliche Anzahl an Stichproben notwendig, bis eine stochastisch belastbare Aussage über die Lage des Stichproben-Mittelwerts (zu einem gewählten Signifikanzniveau) möglich ist.

Um den dargestellten charakteristischen Anforderungen und dem gezeigten Mangel an Standardansätzen zur simulationsbasierten Optimierung von Parametern einer agentenbasierten Simulation zu begegnen, werden im verbleibenden Teil dieses Kapitels verschiedene geeignete Verfahren identifiziert und detailliert. In Kapitel 7 schließt sich dann ein experimenteller Vergleich der Verfahren zur Ermittlung deren Tauglichkeit für konkrete Beispielprobleme an.

6.2. Ausgewählte Verfahren

Geeignete Verfahren zur SBO müssen, wie im vorangegangenen Kapitel dargestellt, eine zerklüftete und stochastische Oberfläche der Zielfunktionsauswertungen sowie eine hohe Dimensionalität des Suchraumes direkt berücksichtigen oder zumindest mit diesen Problemcharakteristika umgehen können.

Zur Adressierung der zerklüfteten Oberfläche müssen die Verfahren sowohl eine lokale Verbesserungskomponente zur Optimierung innerhalb stetiger Teilbereiche beinhalten (z. B. einen sogenannten Hill-climbing-Algorithmus) als auch das Steckenbleiben in lokalen Optima verhindern. Umgekehrt erscheinen diejenigen Optimierungsansätze aufgrund der zerklüfteten Oberfläche als wenig geeignet, die anhand funktionaler Annahmen über die Struktur der Oberfläche ein Metamodell der Simulation entwickeln, wie die in Kapitel 5.2.1 vorgestellten Response Surface Method (RSM) und Neuronale Netze (vgl. [Barton und Meckesheimer 2006]).

Zur Berücksichtigung der Stochastik in der Simulation haben sich zwei unterschiedliche Ansätze etabliert. Standardmäßig verwenden Verfahren hierzu mehrfache Replikationen, um für einen Punkt einen aussagekräftigen Mittelwert zu erzielen. Dergestalt lassen sich ähnliche Methoden wie bei der deterministischen Optimierung auch für stochastische Probleme anwenden – siehe hierzu z. B. die in den folgenden Kapiteln beschriebenen „Global Random Search“ (Kap. 6.2.1) und „NELS“ (Kap. 6.2.4). Einzelne Verfahren umgehen jedoch die genaue Bewertung einzelner Lösungen entlang des Optimierungsverlaufs, indem sie sich wenig anfällig gegenüber einer nur unscharfen Bewertung dieser Lösungen zeigen (wie der in Kap. 5.2.2 vorgestellte SPSA, vgl. [Spall 2003], Kap. 7). Generelles Ziel eines gegenüber der inhärenten Stochastik robusten Verfahrens muss es aber in beiden Fällen sein, die Über- oder Unterschätzung einzelner Lösungen zu minimieren (vgl. [Olafsson 2006]). Hierfür bietet sich die Anlehnung an statistisch ermittelte Signifikanzaussagen über eine Stichprobe aus mehreren Replikationen an.

Schließlich darf ein universell geeignetes Verfahren keine prinzipbedingten Einschränkungen der Dimensionalität des Suchraumes voraussetzen. Mehr noch, es muss sich als robust auch in hochdimensionalen Problemstellungen erweisen und somit auch hier eine Lösung für praktische Fälle in akzeptabler Zeit ermöglichen.

Bei der theoretischen Betrachtung von Algorithmen wird ein Verfahren häufig dadurch gerechtfertigt, dass es die theoretische Konvergenz in einem lokalen Optimum garantiert. „Theoretisch“ bedeutet in diesem Fall eine Grenzwertbetrachtung, d. h., dass hierzu ggf. unendlich viele Iterationen des Algorithmus notwendig sein können. Dies entspricht jedoch nicht den Anforderungen an ein praktisch anwendbares Verfahren. Stattdessen steht bei den hier betrachteten Verfahren die empirische Leistungsfähigkeit auf zufällig gewählten Beispielprobleminstanzen im Vordergrund, die einerseits für alle Verfahren mess- und vergleichbar ist, sich andererseits aber auch auf ähnliche Problemstellungen verallgemeinern lässt.

Bei der Auswahl eines geeigneten Optimierungsverfahrens besteht die erste und grundsätzliche Herausforderung darin, einen Algorithmus zu finden, der für die Struktur des zugrunde liegenden Problems eine bessere bzw. schnellere Lösung bietet als eine reine Zufallsuche (vgl. das in Kap. 5.2 diskutierte „No free lunch“-Theorem). Der im folgenden Kapitel 6.2.1 vorgestellte Algorithmus „Global Random Search“ implementiert genau eine solche Zufallssuche und dient deshalb als Ausgangspunkt und untere Schranke für die Identifikation geeigneter Algorithmen zur Lösung einer konkreten Problemstellung.

Geht man über die reine Zufallssuche hinaus, findet man üblicherweise fortgeschrittene Algorithmen, die das Optimierungsproblem aus zwei unterschiedlichen Stoßrichtungen kombiniert adressieren: Mit Komponenten zur Globalsuche (*Diversifikation*) wird eine Abdeckung des gesamten Lösungsraumes erzielt, parallel dazu wird aber auch mit Komponenten zur Lokalsuche (*Intensivierung*) eine lokale Verbesserung bisher gefundener Lösungen angestrebt. [Andradottir und Prudius 2009] weisen zurecht darauf hin, dass hier die Balance zwischen der Diversifikation und Intensivierung entscheidend ist. In allen im Folgenden vorgestellten Algorithmen wird diese Balance deshalb über den gesamten Optimierungslauf aufrechterhalten, d. h., es findet bewusst kein irreversibler Wechsel von einer anfänglichen Globalsuche hin zu einer Lokalsuche am Ende des Optimierungslaufs statt. Der in Kapitel 5.2.2 beschriebene SPSA in seiner ursprünglichen Ausprägung würde diesem Leitgedanken nicht entsprechen, weshalb im folgenden Kapitel 6.2.3 eine entsprechende Modifikation dieses Algorithmus vorgestellt wird.

Unter Berücksichtigung der eingangs aufgezeigten Kriterien seien aus dem Fundus der Standardansätze zur SBO (vgl. Kap. 5.2) zwei repräsentative State-of-the-art-Verfahren ausgewählt, deren vermutete Eignung für die Optimierung einer ABS im Folgenden näher analysiert wird: „SPSA“ als ein gradientenbasiertes Standardverfahren sowie „NELS“ als eine mengenbasierte evolutionäre Metaheuristik. Zusätzlich wird ein Hybridverfahren betrachtet, das die Vorteile dieser beiden Algorithmen kombinieren soll. Mögliche Alternativen zu den hier ausgewählten Verfahren wären die Tabusuche oder Simulated Annealing (vgl. jeweils Kap. 5.2.3.1), beide Verfahren werden in vielen Publikationen zur SBO ebenfalls als geeignet identifiziert und erfolgreich eingesetzt.

Als Benchmark für die Leistungsfähigkeit der untersuchten Verfahren dient zum einen als untere Schranke die Zufallssuche („Global Random Search“). Diese Schwelle muss jeder Algorithmus übertreffen, um als prinzipiell geeignet für die Lösung einer konkreten Problemstellung zu gelten. Am oberen Ende der möglichen Leistungsfähigkeit angesiedelt ist zum anderen das im industriellen wie auch akademischen Bereich etablierte und bereits in Kapitel 5.2.5 erwähnte kommerzielle Optimierungspaket OptQuest, das aufgrund seiner anerkannten Leistungsfähigkeit für eine Vielzahl von Problemstellungen der SBO einen geeigneten Vergleichsmaßstab darstellt.

Allen vorgestellten Implementierungen der Algorithmen ist gemein, dass sie keine Mindest- oder Höchstanzahl an Zielfunktionsauswertungen voraussetzen, und darüber hinaus zu jedem Zeitpunkt unter Rückgabe der bis dahin besten gefundenen Lösung abbrechbar bzw. unendlich weiterführbar sind, also eine sequenzielle Optimierung nach Kapitel 5.1.2

implementieren. Damit lassen sich die Verfahren innerhalb einer Vielzahl unterschiedlicher Rahmenbedingungen anwenden. Alle Algorithmen sind für ein Maximierungsproblem formuliert, was jedoch keine Einschränkung hinsichtlich der ebenso gegebenen Eignung für Minimierungsprobleme bedeutet, die sich durch eine entsprechende Transformation der Problemstellung herstellen ließe.

Die beschriebenen Implementierungen der Algorithmen orientieren sich primär an der Absicht, die Verfahren in der Gegenüberstellung ihrer Leistungsfähigkeit möglichst vergleichbar zu halten. Eine für einen speziellen Einsatzfall dediziert entwickelte Implementierung könnte demnach effizienter agieren, z. B. eine in Testläufen a priori ermittelte untere Schranke des erwarteten Zielfunktionswerts mitführen, oder auch die finale Evaluation und Auswahl hinsichtlich der besten Lösung lediglich am Ende des Optimierungslaufs aus einer Menge guter Lösungen durchführen.

Formal gegeben sei (analog zu Kap. 5.1) der Definitionsbereich $\Theta \in \mathbb{R}^n$ der n Optimierungsvariablen $\theta = (\theta_1, \dots, \theta_n)$. Die Variablen sind hierbei durch die Untergrenze $\bar{\mathbf{U}} = (\bar{U}_1, \dots, \bar{U}_n)$ und die Obergrenze $\bar{\mathbf{O}} = (\bar{O}_1, \dots, \bar{O}_n)$ beschränkt, sodass für jede Variable gilt: $\bar{\mathbf{U}} \leq \theta \leq \bar{\mathbf{O}}$. Der Skalierungsfaktor $\bar{\lambda} = (\bar{\lambda}_1, \dots, \bar{\lambda}_n)$ bildet die Größenordnung des Lösungsraumes ab und sei gegeben durch $\bar{\lambda} = \bar{\mathbf{O}} - \bar{\mathbf{U}}$. Im Falle einer Einschränkung des Definitionsbereichs auf diskrete Lösungspunkte gilt zusätzlich eine Rasterschrittweite $\bar{\mathbf{W}} = (\bar{W}_1, \dots, \bar{W}_n)$ mit $(\bar{\mathbf{O}} - \bar{\mathbf{U}}) \bmod(\bar{\mathbf{W}}) = 0$. Die Zielfunktion $\phi(\theta)$ sei der Stichproben-Mittelwert von m Replikationen der Simulation mit einem bestimmten Lösungskandidaten $\bar{\theta}$ und einer im Rahmen von Verteilungsannahmen zufällig gewählten m Realisation der Zufallsvariablen \mathbf{y} , es gilt also $\phi(\bar{\theta}) = \frac{1}{m} \cdot \sum_{i=1}^m \phi_i(\bar{\theta}, \mathbf{y}_i)$. Es gilt ferner eine Budgetbeschränkung von \bar{s} Simulationsläufen zur gesamten Durchführung eines Optimierungslaufs, darüber hinaus je untersuchtem Lösungskandidaten eine minimale und maximale Anzahl an Simulationsläufen (\bar{s}_{ϕ}^{\min} und \bar{s}_{ϕ}^{\max}) zur Evaluation des Zielfunktionswerts.

6.2.1. Global Random Search (GRS)

Der Algorithmus „Global Random Search“ entspricht einer zufälligen globalen Suche (vgl. [Spall 2003], S. 38), bei der iterativ neue Lösungskandidaten beliebig innerhalb des Definitionsbereichs generiert und daraufhin evaluiert werden, ob sie besser sind als die bisher beste gefundene Lösung. Charakteristisch für dieses Verfahren ist, dass neue Lösungskandidaten rein zufällig ausgewählt werden, ohne die aus vorangegangenen Lösungskandidaten gewonnenen Erkenntnisse, beispielsweise hinsichtlich Güte oder Varianz, zu berücksichtigen. Entsprechend einfach ist die Implementierung des Algorithmus, wie Abbildung 35 darstellt.

Es handelt sich hierbei also um ein auf die minimal notwendigen Elemente reduziertes Verfahren, bei dem keine Annahmen über die Struktur der Oberfläche der Zielfunktionsauswertungen notwendig sind. Dies ergibt zwangsläufig, dass ein alternatives und damit per se aufwendiger strukturiertes Verfahren diesem Algorithmus z. B. hinsichtlich Lösungsgüte oder notwendigem Ressourceneinsatz überlegen sein muss, um seinen Einsatz zu rechtfertigen.

Trotz der Einfachheit kann für dieses Verfahren ein formaler Konvergenzbeweis geführt werden, wie [Pflug 1992] (S. 54) und [Spall 2003] (S. 40) zeigen. [Pflug 1992] merkt allerdings auch an, dass die Effizienz des Algorithmus bei komplexeren, hochdimensionalen Problemen leidet und in einer niedrigen Konvergenzgeschwindigkeit resultiert.

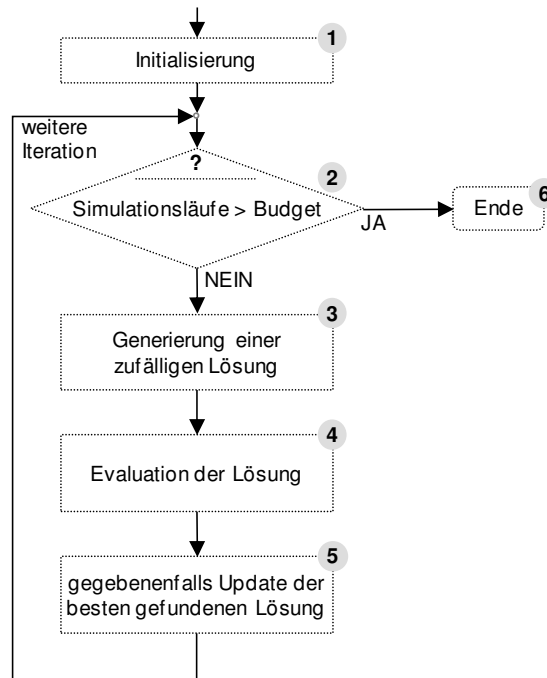


Abbildung 35: Ablaufdiagramm des Algorithmus "Global Random Search"

Quelle: eigene Darstellung

Ablauf des Algorithmus „Global Random Search“

(Formulierung für ein Maximierungsproblem)

1. Initialisierung:
 - Zähler der Simulationsläufe $s := 0$
 - Beste Lösung θ^* mit $\phi(\theta^*) := -M$ (hinreichend kleine Zahl)
2. Prüfung, ob bisherige Anzahl der Simulationsläufe s das Budget \bar{s} überschreitet
3. Generierung eines zufällig bestimmten Lösungskandidaten $\theta \in \Theta$
4. Evaluation des Lösungskandidaten θ :
 - Berechnung des Zielfunktionswerts $\phi(\theta)$ durch mehrmalige Replikation, wobei die Prüfung der Notwendigkeit weiterer Replikationen mit dem Evaluationskriterium2 (siehe S. 104) unter Berücksichtigung von \bar{s}_{ϕ}^{min} , \bar{s}_{ϕ}^{max} und $\phi(\theta^*)$ erfolgt
 - Erhöhung des Zählers der Simulationsläufe um benötigte Anzahl m der zur Evaluation verwendeten Replikationen $s := s + m$
5. Falls Verlaufslösung θ besser ist als bisher beste Lösung θ^* , d. h. wenn gilt $\phi(\theta) > \phi(\theta^*)$, Update der besten Lösung $\theta^* := \theta$ mit $\phi(\theta^*) := \phi(\theta)$

6.2.2. OptQuest

Als ein kompetitiver Benchmark für die anderen im Rahmen dieser Arbeit implementierten Optimierungsverfahren dient die kommerzielle Optimierungssoftware OptQuest, welche direkt in der Simulationsumgebung AnyLogic eingebettet ist. Dieses Optimierungsverfahren ist auch in anderen Simulationspaketen weit verbreitet (vgl. [Fu 2002]) und reklamiert in seiner zugehörigen Dokumentation, die nach Expertenmeinung zuverlässigste Optimierungslösung auf dem Markt zu sein (vgl. [OptTek 2008]). Diese Behauptung konnte im Rahmen der vorliegenden Arbeit zwar nicht näher hinterfragt werden, trotzdem lässt sich der Algorithmus zumindest als ein geeigneter Benchmark für die anderen implementierten Optimierungsverfahren ansehen. In der Literatur zur SBO wird OptQuest ebenfalls als geeigneter Benchmark betrachtet und vielfach verwendet, z. B. von [Xu et al. 2010].

Für OptQuest stellt die Simulation eine komplexe Blackbox dar, von der lediglich (ggf. stochastische) Zielfunktionsauswertungen für gegebene Werte der Optimierungsvariablen ermittelbar sind. Dadurch eignet sich der Solver universell für prinzipiell jede Art von Simulation, ohne problemspezifische Informationen zu benötigen.

Da OptQuest ein kommerzielles Produkt ist, findet man die genaue Implementierung des Algorithmus nur in Grundzügen öffentlich publiziert (vgl. [Kleijnen und Wan 2007]). Kernelement ist eine metaheuristische Suche basierend auf Scatter Search (vgl. Kap. 5.2.3.2). [Glover et al. 1999], [Laguna 1997], [Laguna und Marti 2002] und [Laguna und Marti 2003] (Kap. 9) zeigen grob den Ablauf des Algorithmus, bei dem iterativ aus einer Menge von Referenzlösungen durch Linearkombination neue äquidistante Lösungen generiert werden. Diese werden mit ihren Ausgangslösungen verglichen und ersetzen diese gegebenenfalls in den darauffolgenden Iterationen. Dabei werden durch eine Extrapolation auch Lösungen außerhalb der konvexen Hülle der bisherigen Lösungen als neue Lösungen einbezogen. Somit ist der Suchraum nicht auf die konvexe Hülle der initialen Referenzlösungen beschränkt. Die Kombination der Lösungen erfolgt nicht zufällig, sondern folgt einem Schema, das gerade gemachte Inter- oder Extrapolationsschritte kurzfristig „tabu“ setzt, also ausschließt. Je nach Güte der einbezogenen Lösungen wird auch die Menge und Distanz der neu generierten Lösungen adaptiv gesteuert und ermöglicht so eine Intensivierung in vielversprechenden Bereichen des Lösungsraumes. Als Ausgangspunkt dient dem Algorithmus eine mit möglichst hoher Diversität gewählte Menge an Referenzlösungen, die den gesamten Lösungsraum umspannen und insbesondere die Eck- und Mittelpunkte beinhalten. Ändert sich die Menge der Referenzlösungen im Optimierungsverlauf nicht mehr, so wird der Algorithmus unter Beibehaltung einer begrenzten Anzahl der bisher besten (elitären) Lösungen neu gestartet.

Um offensichtlich schlechte Lösungen frühzeitig von einer eingehenden Untersuchung auszuschließen, kann OptQuest ein Neuronales Netz als Ersatzmodell (vgl. Kap. 5.2.1) mit den bis dahin durchgeführten Simulationsauswertungen trainieren und dieses zur Einschätzung von Lösungen verwenden. Es gibt jedoch keine Anzeichen, dass diese prinzipiell vorhandene Funktionalität aus AnyLogic heraus genutzt wird.

Die bisher zitierten Quellen zur Funktionsweise beziehen sich lediglich auf deterministische Probleme. Erst ein Blick in das Entwicklerhandbuch von OptQuest (vgl. [OptTek 2008]) offenbart auch die Fähigkeiten des Algorithmus zur Lösung stochastischer Optimierungsprobleme. OptQuest verwendet dann, wie auch im Grundproblem in Kap. 5.1 dargestellt, mehrere Replikationen einer stochastischen Simulation mit identischen Wertbelegungen der Optimierungsvariablen, um anhand des Stichproben-Mittelwerts eine Bewertung der Lösung vorzunehmen. Der Algorithmus nutzt hierzu entweder eine vom Anwender vorgegebene fixe Anzahl an Replikationen oder definierte Schranken für die Mindest- und Höchstanzahl der Replikationen. Zwischen diesen Schranken entscheidet er vermutlich (wie auch [Kleijnen und Wan 2007] jedoch ohne Quellenangabe skizzieren) anhand eines statistischen Tests analog zu der sequenziellen Prozedur aus [Law 2007] (S. 502), ob weitere Replikationen zur Evaluation der Lösung notwendig sind. Die gewünschte Konfidenz sowie eine akzeptable relative Abweichung des Mittelwerts als prozentualer Fehler vom störungsfreien Zielfunktionswert müssen dabei vom Benutzer als Parameter vorgegeben werden.

6.2.3. Simultaneous Perturbation Stochastic Approximation (SPSA)

Der SPSA („Simultaneous Perturbation Stochastic Approximation“, aus [Spall 1998b]) ist ein bekannter Standardalgorithmus zur simulationsbasierten Optimierung stochastischer Systeme (für eine ausführliche Vorstellung und Diskussion siehe [Spall 2003], Kap. 7), der sich bereits in einer Vielzahl praktischer Anwendungsfälle etabliert hat (z. B. im Revenue Management bei [Gosavi et al. 2007]; für eine umfangreiche Auflistung vgl. die Website von James C. Spall³²). Es handelt sich hierbei um ein Gradientenverfahren, bei dem iterativ von einer Verlaufslösung die Richtung der bestmöglichen Verbesserung gesucht und dann in diese Richtung ein Schritt zu einer neuen Verlaufslösung durchgeführt wird. Eine der im Verlauf betrachteten Lösungen bzw. die letzte erreichte Lösung dienen als Ergebnis der Optimierung.

Wenn Gradienten mangels einer funktional definierten Zielfunktion nicht direkt ableitbar sind, muss die Richtung der Verbesserung approximiert werden (vgl. [Spall 2003], Kap. 6). Dies geschieht beim SPSA lediglich mit zwei stochastischen Zielfunktionsauswertungen je Verlaufslösung (unabhängig von der Dimensionalität des Optimierungsproblems), wobei diese an gegenüberliegenden Punkten in der Umgebung der Verlaufslösung durchgeführt werden. Diese spezielle Art der Stochastischen Approximation (SA) basiert auf der Idee, dass die präzisere Schätzung des Gradienten in einem Punkt anhand der jeweiligen Gradienten der einzelnen Optimierungsvariablen (wie beim FDSA, siehe z. B. [Spall 2003], Kap. 6) eine Verschwendung von Ressourcen ist (vgl. [Spall 2003], S. 97). Zwar ist die Gradientenschätzung anhand lediglich zweier Zielfunktionsauswertungen je Verlaufslösung deutlich ungenauer, über den Verlauf der Optimierung hinweg gleichen sich die so erkaufte ungenaueren Schritte aber aus.

³² http://www.jhuapl.edu/SPSA/Pages/References-List_Ref.htm, abgerufen am 18. Januar 2010.

In seiner ursprünglichen Form ist der SPSA für die lokale Optimierung konzipiert und setzt dort die Existenz einer eindeutigen Extremstelle voraus (vgl. [Spall 2003], S. 105). Durch eine sukzessive Reduktion der Schrittweite im Optimierungsverlauf wird die asymptotische Konvergenz in solch einer optimalen Lösung sichergestellt. Für die in der vorliegenden Arbeit benötigte Globaloptimierung ist es aber notwendig, die verfrühte Konvergenz und somit ein Steckenbleiben in einem lokalen Optimum zu verhindern. Hierfür existieren verschiedene Ansätze, [Spall 2003] (Kap. 8.4) und [Maryak und Chin 2008] beschreiben z. B. ein injiziertes Rauschen zusätzlich zu dem in der Simulation inhärenten Rauschen, das zu zufälligen Sprüngen der Verlaufslösung im Lösungsraum führen kann. Zwar weisen [Maryak und Chin 2008] außerdem darauf hin, dass sich auch der ursprüngliche Algorithmus durch das bereits eingebaute Rauschen zumindest theoretisch zur Globaloptimierung eignen kann, für die hier betrachteten praktischen Problemstellungen konnte dieser Ansatz in empirischen Testläufen jedoch nicht überzeugen.

Eine andere Möglichkeit, die im Folgenden näher ausgeführt und verwendet wird, besteht darin, nach einer gewissen Zeit ohne Verbesserung der Verlaufslösung diese über den normalen SPSA-Iterationsschritt hinaus zu verändern, d. h. ebenfalls einen Sprung im Lösungsraum auszulösen. Zwar kann man so keine homogene Abdeckung des gesamten Lösungsraumes sicherstellen, zumindest wird aber ein Steckenbleiben in lokalen Optima wirksam verhindert. Durch diese Modifikationen des ursprünglichen SPSA wird die asymptotische Konvergenz in einem lokalen Optimum verlangsamt oder sogar verhindert; für die Leistungsfähigkeit zur Globaloptimierung auf praktischen Problemstellungen mit zerklüfteter, nicht konvexer Oberfläche sind formale Konvergenzeigenschaften aber ohnehin von untergeordneter Bedeutung. Die empirischen Analysen in Kapitel 7.4 werden im Gegenteil zeigen, dass gerade ein dergestalt modifizierter SPSA eine hohe Leistungsfähigkeit für praktische Problemstellungen der simulationsbasierten Globaloptimierung aufweist.

Infolge seiner ursprünglichen Ausrichtung auf die gradientenbasierte Lokalsoptimierung ist zu erwarten, dass der SPSA seine Stärken vor allem bei einer von monotonen Steigungen geprägten Oberfläche ausspielen kann. Außerdem sollte sich der Algorithmus vergleichsweise robust und effizient gegenüber einer Varianz in den Zielfunktionsauswertungen zeigen. Diese Problemcharakteristik wird, im Gegensatz zu vielen anderen Algorithmen, nicht indirekt erst durch eine Mittelwertbildung im Rahmen mehrfacher Replikation berücksichtigt, sondern direkt innerhalb des Algorithmus durch eine Glättung über mehrere Iterationen hinweg einbezogen.

Die Beschränkung auf einen diskreten Lösungsraum stellt keine Einschränkung für den SPSA dar, zumindest solange auch dann eine aussagekräftige Gradientenbildung im kontinuierlichen Raum möglich ist. In einem solchen Fall ist die Zielfunktion zwar im kontinuierlichen Raum definiert und auswertbar, aber als finale Lösungen sind nur diskrete Punkte erlaubt.

Die Implementierung des bereits skizzierten modifizierten SPSA zur Globalsuche ist in Abbildung 36 dargestellt und im Folgenden näher ausgeführt.

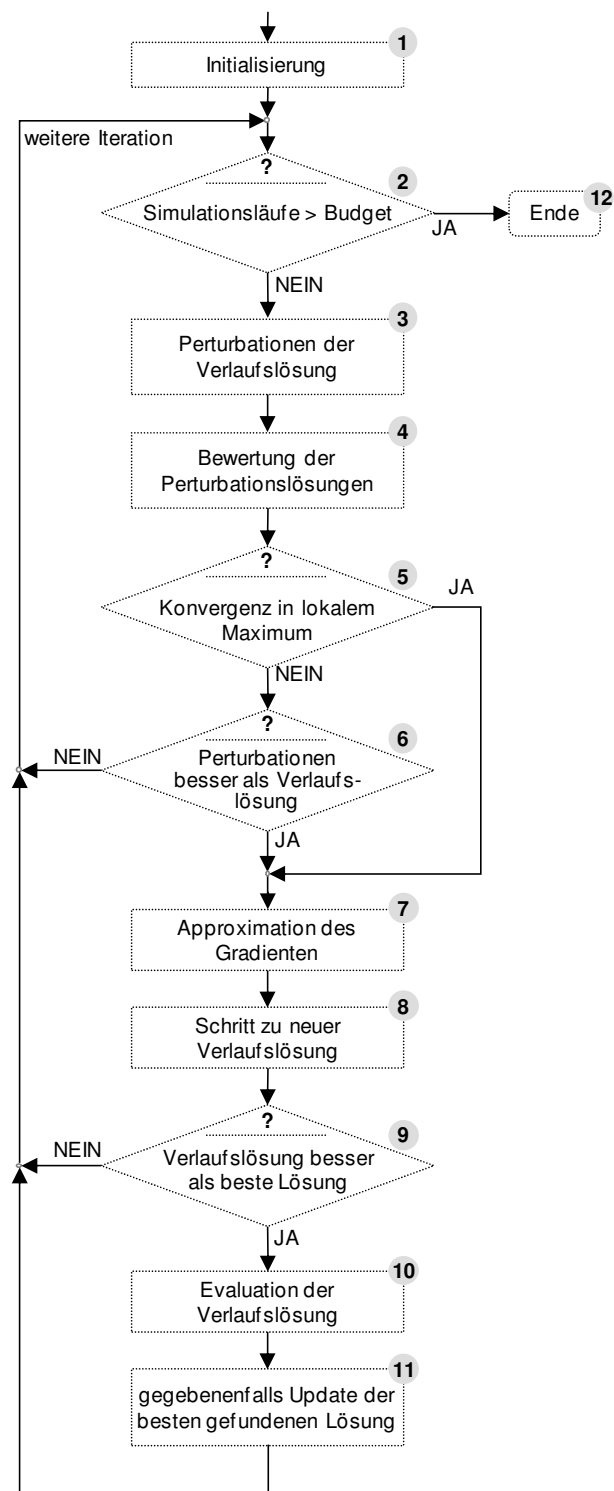


Abbildung 36: Ablaufdiagramm des Algorithmus „SPSA“

Quelle: eigene Darstellung

Ablauf des Algorithmus „SPSA“ (Formulierung für ein Maximierungsproblem)

Gegeben: Werte für die Standardparameter des SPSA-Algorithmus \bar{c} , $\bar{\gamma}$, \bar{a} , \bar{A} , $\bar{\alpha}$; Werte für die Iterationsschwellen \bar{h}_1 und \bar{h}_2 mit $\bar{h}_1 < \bar{h}_2$; Störungsbreite \bar{b} ; Skalierungsfaktor $\bar{\lambda}$

1. Initialisierung:
 - Zähler der Simulationsläufe $s := 0$
 - Iterationszähler $i := 0$ (gesamter Optimierungsablauf) und $h := 0$ (aktuelle Verlaufslösung)
 - Start mit zufällig bestimmter Verlaufslösung $\theta \in \Theta$ mit $\phi(\theta) := -M$ (hinreichend kleine Zahl)
 - Beste Lösung $\theta^* := \theta$
2. Prüfung, ob bisherige Anzahl der Simulationsläufe s das Budget \bar{S} überschreitet
3. Perturbation der Verlaufslösung θ :
 - Perturbationsvektor ρ_i durch n-malige unabhängige Ziehung einer Bernoulli ± 1 verteilten Zufallsvariablen erzeugen
 - Koeffizient berechnen $c_i = \bar{c}/(i+1)^{\bar{\gamma}}$
 - Schrittweite berechnen $\Delta_i^c = \bar{\lambda} \cdot c_i \cdot \rho_i$
 - Falls Konvergenz in lokalem Maximum droht, d. h., wenn Zähler der Iterationen ohne Veränderung der Verlaufslösung $h > \bar{h}_1$, Erhöhung von Δ_i^c um eine zufällige Störung von bis zu \bar{b} Rasterschrittweiten \bar{W}
 - Perturbationslösungen erzeugen $\theta^+ := \theta + \Delta_i^c$ und $\theta^- := \theta - \Delta_i^c$
 - Falls Perturbationslösungen θ^+ oder θ^- die Unter- bzw. Obergrenzen der Variablen überschreiten, Korrektur auf den nächstgelegenen Punkt auf dem Rand des Definitionsbereichs Θ
4. Bewertung der Perturbationslösungen θ^+ und θ^- :
 - Berechnung von $\phi(\theta^+)$ und $\phi(\theta^-)$ jeweils durch einmalige Simulation
 - Zähler der Simulationsläufe erhöhen $s := s + 2$
5. Prüfung, ob Konvergenz in einem lokalen Maximum vorliegt, d. h., ob Zähler der Iterationen ohne Veränderung der Verlaufslösung $h > \bar{h}_2$ ist, dann Schritt zu neuer Verlaufslösung ohne Akzeptanzschwelle (vgl. Schritt 6.)
6. Prüfung, ob zumindest eine der Perturbationslösungen besser als die Verlaufslösung ist, d. h., ob $\max\{\phi(\theta^+); \phi(\theta^-)\} > \phi(\theta)$ gilt, sonst Beibehaltung der aktuellen Verlaufslösung θ und Erhöhung des Iterationszählers $h := h + 1$
7. Approximation des Gradienten berechnen $g_i = \frac{\phi(\theta^+) - \phi(\theta^-)}{2 \cdot \Delta_i^c}$
8. Schritt zu neuer Verlaufslösung θ :
 - Koeffizient berechnen $a_i = \bar{a}/(i+1 + \bar{A})^{\bar{\alpha}}$
 - Schrittweite berechnen $\Delta_i^A = (\bar{\lambda} \cdot a_i) \cdot (\bar{\lambda} \cdot g_i) = \bar{\lambda}^2 \cdot a_i \cdot g_i$
 - Schritt zu neuer Verlaufslösung $\theta := \theta + \Delta_i^A$
 - Falls neue Verlaufslösung θ die Unter- bzw. Obergrenzen der Variablen überschreitet, Korrektur auf den nächstgelegenen Punkt auf dem Rand des Definitionsbereichs Θ
 - Vorläufige Bewertung der neuen Verlaufslösung $\phi(\theta) := \frac{1}{2} \cdot [\phi(\theta^+) + \phi(\theta^-)]$
 - Iterationszähler aktualisieren $i := i + 1$ und $h := 0$
9. Prüfung, ob zumindest eine der Perturbationslösungen besser war als die bisher beste Lösung, d. h., ob $\max\{\phi(\theta^+); \phi(\theta^-)\} > \phi(\theta^*)$ gilt
10. Evaluation der Verlaufslösung θ :
 - Falls neue Verlaufslösung θ nicht auf einem der zulässigen Rasterpunkte (falls zutreffend) liegt, Korrektur auf den nächstgelegenen Rasterpunkt $\theta \in \Theta$
 - Berechnung von $\phi(\theta)$ durch mehrmalige Replikation, wobei die Prüfung der Notwendigkeit weiterer Replikationen mit dem Evaluationskriterium² (siehe S. 104) unter Berücksichtigung von \bar{S}_ϕ^{\min} , \bar{S}_ϕ^{\max} und $\phi(\theta^*)$ erfolgt
 - Zähler der Simulationsläufe um benötigte Anzahl m der zur Evaluation verwendeten Replikationen erhöhen $s := s + m$
11. Falls evaluierte Verlaufslösung θ besser ist als bisher beste Lösung θ^* , d. h. wenn gilt $\phi(\theta) > \phi(\theta^*)$, Update der besten Lösung $\theta^* := \theta$ mit $\phi(\theta^*) := \phi(\theta)$
12. Ende des Algorithmus: Präsentation der besten Lösung θ^* mit dem Zielfunktionswert $\phi(\theta^*)$

Für die Standardparameter des SPSA-Algorithmus gibt [Spall 2003] (Kap. 7.5.2) die Werte $\bar{\alpha} = 0,602$ und $\bar{\gamma} = 0,101$ an, welche zum einen die kleinstmögliche Belegung für diese Parameter zur Aufrechterhaltung der theoretischen Eigenschaften des Algorithmus darstellen, zum anderen aber auch eine gute Eignung in praktischen Anwendungsfällen gezeigt haben – kleine Werte sind hierbei durch die Aufrechterhaltung einer größeren Schrittweite häufig von Vorteil. Die Werte von $\bar{A} = 5.000$ und $\bar{c} = 0,1$ sind ausgehend von den bei [Spall 2003] (Kap. 7.5) formulierten Regeln für die später in Kapitel 7.1 beschriebene Verwendung experimentell ermittelt. Ebenfalls diesen Regeln folgend basiert der Wert $\bar{\alpha} = 0,00002$ auf den übrigen Parametern sowie auf der Größenordnung des Zielfunktionswerts. Die Werte für die Iterationsschwellen \bar{h}_1 , \bar{h}_2 und die Störungsbreite \bar{b} sollen problemadäquat gewählt werden, für die vorliegende Arbeit wurden $\bar{h}_1 = 5$ und $\bar{h}_2 = 20$ sowie $\bar{b} = 5$ wiederum experimentell bestimmt und entsprechend verwendet.

Der Skalierungsfaktor $\bar{\lambda}$ dient dazu, die Schrittweite des SPSA problemspezifisch zu steuern. Unterscheiden sich die Skalen der Optimierungsvariablen stark, so bietet es sich an, die Schrittweite des SPSA je Variable unterschiedlich mittels $\bar{\lambda}$ (als Vektor) zu transformieren. Die Multiplikation von ρ_i bzw. g_i mit diesem Vektor ist dann als jeweils separate Multiplikation der Vektorkomponenten miteinander aufzufassen. In der vorliegenden Arbeit wird $\bar{\lambda}$ mit der Spannweite des Definitionsbereiches Θ belegt, also $\bar{\lambda} = \bar{\Theta} - \bar{U}$, um so die unterschiedlichen Skalen der Optimierungsvariablen anzugleichen.

Die grundlegende Modifikation des ursprünglichen SPSA-Algorithmus besteht bei diesem Ansatz darin, dass nicht jeder der in Schritt 7 approximierten Gradienten als Grundlage eines Schritts zu einer neuen Verlaufslösung herangezogen wird. Vielmehr wird der Schritt nur dann auch vollzogen, wenn zumindest eine der zugrunde liegenden Perturbationslösungen indikativ (auf Basis lediglich einer Simulationsauswertung) besser ist als die aktuelle Verlaufslösung. Diese Akzeptanzschwelle für den Gradienten (in der Literatur auch als *blocking* bezeichnet, siehe [Spall 1998a]) ist notwendig, um in der hochgradig zerklüfteten Oberfläche einer agentenbasierten Simulation (vgl. Kapitel 6.1) ein vorschnelles Abdriften zu verhindern. Andernfalls würde im häufig vorkommenden Fall zweier vergleichsweise schlechter Perturbationslösungen der Schritt zu einer neuen Verlaufslösung anhand eines für die Optimierung kaum aussagekräftigen Gradienten durchgeführt.

Zusätzlich werden Vorkehrungen getroffen, die eine verfrühte Konvergenz in einem lokalen Optimum verhindern. Findet ab einer gewissen Anzahl an Iterationen noch immer kein Schritt zu einer neuen Verlaufslösung statt, so wird der Abstand der Perturbationslösungen von der Verlaufslösung wie in Schritt 3 dargestellt durch ein stochastisches Rauschen vergrößert, um so den Einzugsbereich der Gradientenapproximation zu erweitern. Nach weiteren erfolglosen Iterationen wird schließlich angenommen, dass von der aktuellen Verlaufslösung kein regulärer Schritt zu einer besseren Lösung möglich ist, also ein lokales Maximum gefunden wurde. In diesem Fall wird der approximierte Gradient in Schritt 5 ohne Akzeptanzschwelle verwendet, um einen Schritt zu einer neuen Verlaufslösung zu machen. Dies entspricht konzeptionell einem Ausbruchsversuch aus dem lokalen Maximum und dient somit dem Ziel der Globaloptimierung über dem gesamten Lösungsraum.

Bei der Zielfunktionsauswertung der Perturbationslösungen $\phi(\theta^+)$ und $\phi(\theta^-)$ in Schritt 4 wird dem von [Kleinman et al. 1999] vorgeschlagen Konzept der *Common random numbers*

folgend (vgl. auch [Law 2007], Kap. 11.2) die einmalige Simulation jeweils mit identischen Zufallszahlen zur Reduktion der stochastischen Varianz durchgeführt.

Bei einem Punkt-zu-Punkt-Verfahren wie dem SPSA stellt sich zwangsläufig die Frage, in welchem Umfang einzelne Verlaufslösungen evaluiert werden müssen, oder ob sich mögliche Ungenauigkeiten bei einer vernachlässigten Evaluation über den Optimierungsverlauf hinweg ausgleichen. Ein in der Literatur in diesem Kontext diskutierter Ansatz ist die iterative Durchschnittsbildung („iterate averaging“, vgl. [Spall 2003], Kap. 4.5.3), bei der unter Annahme einer weitgehend kontinuierlichen Konvergenz ein gleitender Durchschnitt der zuletzt untersuchten Lösungen anstatt eines evaluierten besten Zielfunktionswerts herangezogen wird. Dieser Ansatz erfordert folglich keine Evaluation im Optimierungsverlauf, somit wird für jede Lösung nicht mehr als eine Replikation verwendet. Dies ist aber kaum geeignet für die betrachtete Modifikation des SPSA, bei der Sprünge im Lösungsraum möglich sind und eine Konvergenz nicht sichergestellt ist.

Mit dem Ziel, jederzeit eine evaluierte Lösung als bisher beste Lösung mitzuführen und außerdem eine Vergleichbarkeit mit den anderen vorgestellten Verfahren sicherzustellen, wurde in der vorliegenden Arbeit jedoch der Weg gewählt, jede im Optimierungsverlauf ermittelte, hinreichend aussichtsreich erscheinende Verlaufslösung auch vollständig zu evaluieren. Die Entscheidung hinsichtlich der aussichtsreichen Güte einer Lösung fällt in Schritt 9 anhand des Kriteriums, ob zumindest eine der dem Schritt zugrunde liegenden Perturbationslösungen bei der einmaligen Simulation einen besseren Zielfunktionswert gezeigt hat als die bisher beste Lösung.

6.2.4. Evolutionärer Algorithmus NELS

Der NELS („Nachbarschafts-Elite-Selektion“) ist ein vom Autor entworfener evolutionärer Algorithmus, der sich durch die Anwendung eines speziellen Selektionsmechanismus besonders für die in dieser Arbeit betrachtete Problemstellung mit vielen lokalen, potenziell ähnlich guten Optima eignet.

Dieser Algorithmus entspricht in weiten Teilen dem typischen Aufbau eines evolutionären Optimierungsverfahrens, wie es z. B. [Eiben und Smith 2007] (Kap. 2.3) ausführlich erläutern. Eine Ausgangsmenge von Lösungen (die sog. *Population*) wird hierbei durch die Anwendung der evolutionären Operatoren *Variation* (Veränderung in der näheren Umgebung), *Mutation* (Veränderung über den gesamten Definitionsbereich) und *Kreuzung* (Rekombination verschiedener Lösungen) um neue Lösungen erweitert und dadurch diversifiziert. Die so vergrößerte Population bildet den Pool, aus dem die Lösungen für die Ausgangspopulation der folgenden Generation ausgewählt werden, um das Verfahren danach iterativ von Neuem zu starten. Da die Eltern bei dieser sog. $(\lambda + \mu)$ -Selektion (λ bezeichnet hierbei die Menge der Kinder und μ die Menge der Eltern, vgl. [Eiben und Smith 2007], Kap. 4.7) neben den Kindern in der Population verbleiben, spricht man von einem elitären Ansatz (vgl. [Eiben und Smith 2007], S. 66). Dabei können gute Lösungen über mehrere Generationen hinweg erhalten bleiben. Die Grundidee hinter diesem Vorgehen ist ein Analogschluss zur biologischen Evolution, bei der sich ebenfalls über viele Generationen hinweg das Erbgut eines Lebewesens mit vergleichbaren Mechanismen weiterentwickelt, und jeweils

der sprichwörtliche darwinistische Selektionsmechanismus „Survival of the fittest“ für eine Auswahl der besten Lebewesen sorgt.

Bei der Selektion berücksichtigt NELS neben der sog. Fitness einer Lösung – also dem Wert der Zielfunktion des Optimierungsproblems – auch deren Nachbarschaft im Lösungsraum (auch Nische genannt). Hierzu wird als Vorauswahl in der Population eine Bereinigung der Nachbarschaft um andere Lösungen vorgenommen, die eine schlechtere Fitness aufweisen als die jeweils betrachtete Lösung. So wird erreicht, dass eine Lösung in der folgenden Generation genau dann erhalten bleibt, wenn sich in der Nachbarschaft keine bessere Lösung befindet, unabhängig von ihrer Fitness im Vergleich zu anderen, weiter entfernten Lösungen.

Die Anwendung dieser Vorauswahl erscheint vielversprechend, da die inhärente Komplexität der Simulation und die daraus resultierende zerklüftete Oberfläche der Zielfunktionsauswertungen dazu führen, dass die Fitness kein absolutes Maß der Güte einer Lösung für den Ablauf des Algorithmus darstellt. Die Entscheidung, ob eine Lösung „bessere Gene“ als eine andere vorweist und diese damit dominiert, ist deshalb nicht vollständig durch einen Vergleich der Zielfunktionswerte möglich. Innerhalb einer lokal begrenzten Nachbarschaft ist diese Dominanz jedoch leichter argumentierbar, da die Variablenwerte dort per Definition nur geringe Unterschiede aufweisen und somit auch das Potenzial für komplett unterschiedliche komplexe Wirkungsketten innerhalb der Simulation begrenzt ist.

Generell ist zu erwarten, dass der Algorithmus gut mit verschiedenen lokalen Optima umgehen kann, da er ein vergleichbares Selektionsverfahren verwendet wie der populäre Algorithmus NSGA-II von [Deb et al. 2002], der als ein etabliertes Optimierungsverfahren für solche Problemstellungen gilt. Durch die Anwendung dieses Selektionsverfahrens bleiben in der Population stets mehrere Extrempunkte repräsentiert, was eine Clusterbildung in der Umgebung einer einzelnen Lösung verhindert. Die verwendeten Operatoren erscheinen ebenfalls als problemadäquat und aussichtsreich auch für einen hochdimensionalen Suchraum, da mit der Variation und Mutation sowohl eine Intensivierung (Lokalsuche durch kleine Veränderungen einzelner Variablen) als auch eine Diversifikation (Globalsuche durch größere Veränderungen einzelner oder mehrerer Variablen) erzielt wird, während die Kreuzung zusätzlich die Kombination verschiedener guter Lösungskomponenten ermöglicht.

Einige Autoren haben sich mit Überlegungen zu den theoretischen Konvergenzeigenschaften evolutionärer Algorithmen beschäftigt (vgl. z. B. [Spall et al. 2006], Abschnitt 3.5), allerdings lassen sich daraus kaum relevante Schlüsse für das hier betrachtete Verfahren ableiten. Lediglich die empirisch beobachtete gute Performance in einer Vielzahl von Anwendungsfällen spricht für ein solches Verfahren, was sich auch im Rahmen der eingehend betrachteten Problemstellung in Kapitel 7.4 zeigt.

Die konkrete Implementierung dieses Algorithmus ist in Abbildung 37 dargestellt und in einer schrittweisen Anleitung näher ausgeführt:

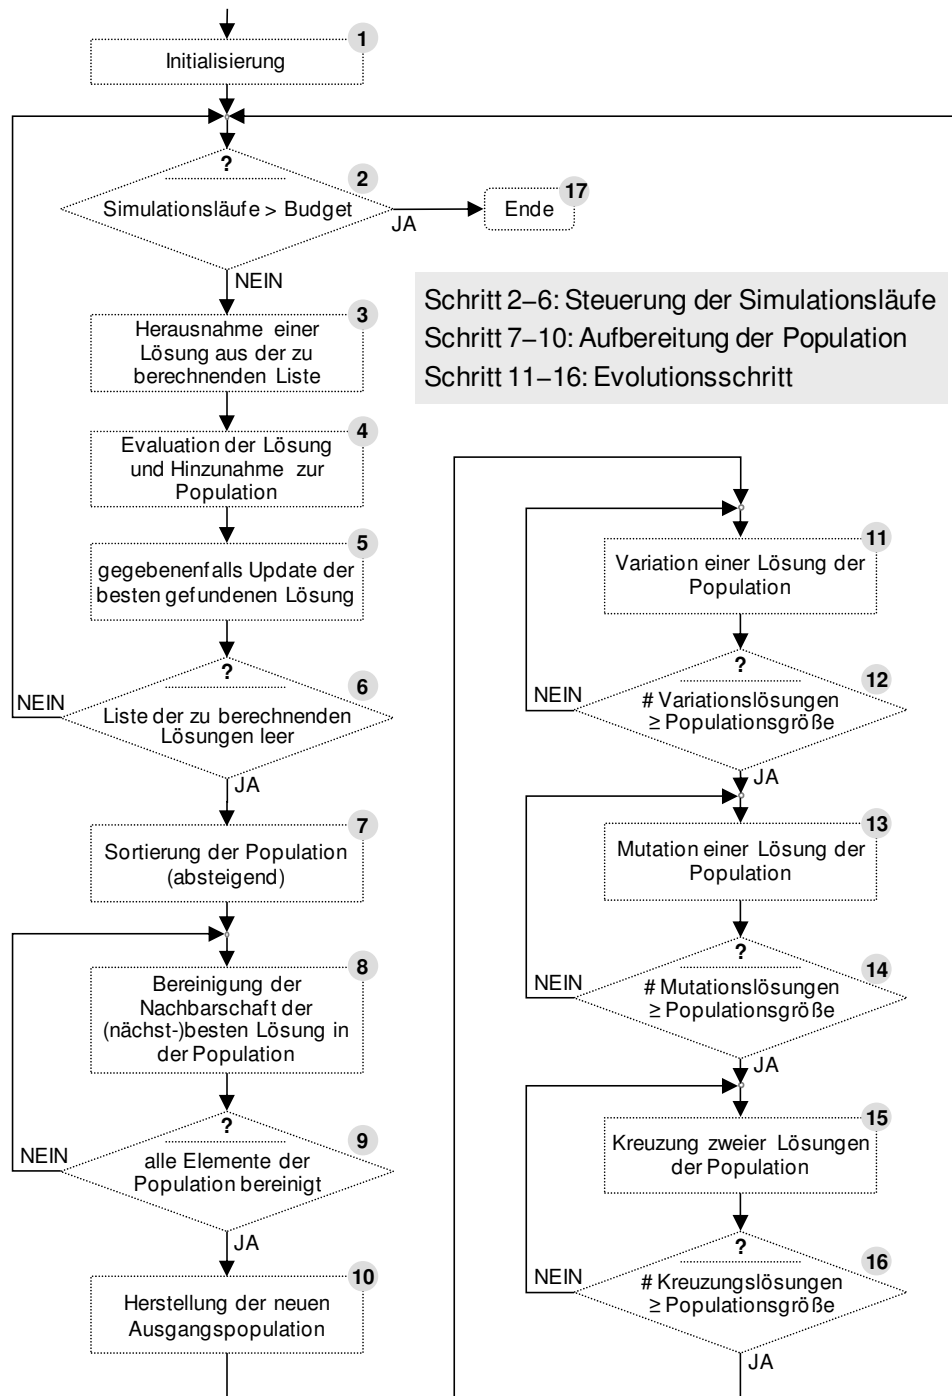


Abbildung 37: Ablaufdiagramm des Algorithmus „NELS“

Quelle: eigene Darstellung

Ablauf des Algorithmus „NELS“ (Formulierung für ein Maximierungsproblem)

Gegeben: Parameterwerte für Populationsgröße \bar{p} und Nachbarschaftsskalierungsfaktor \bar{r}

1. Initialisierung:
 - Zähler der Simulationsläufe $s := 0$
 - Liste von Lösungen $Population := \emptyset$
 - Liste von Lösungen $zuEvaluierten$, initial befüllt mit $3\bar{p}$ zufällig bestimmten Lösungen $\theta \in \Theta$ je mit $\phi(\theta) := -M$ (hinreichend kleine Zahl)
 - Beste Lösung $\theta^* := zuEvaluierten\{0\}$
2. Prüfung, ob bisherige Anzahl der Simulationsläufe s das Budget \bar{s} überschreitet
3. Herausnahme einer beliebigen Lösung θ aus der Liste $zuEvaluierten$
4. Evaluation der Lösung θ und Hinzunahme zur Liste $Population$:
 - Falls Lösung θ die Unter- bzw. Obergrenzen der Variablen überschreitet, Korrektur auf den nächstgelegenen Punkt auf dem Rand des Definitionsbereichs Θ
 - Berechnung von $\phi(\theta)$ durch mehrmalige Replikation, wobei die Prüfung der Notwendigkeit weiterer Replikationen mit dem Evaluationskriterium2 (siehe S. 104) unter Berücksichtigung von \bar{s}_{ϕ}^{min} , \bar{s}_{ϕ}^{max} und $\phi(\theta^*)$ erfolgt
 - Erhöhung Zähler der Simulationsläufe um benötigte Anzahl m an Replikationen $s := s + m$
 - Hinzunahme der evaluierten Lösung θ zur Liste $Population$
5. Falls evaluierte Lösung θ besser ist als bisher beste Lösung θ^* , d. h. wenn gilt $\phi(\theta) > \phi(\theta^*)$, Update der besten Lösung $\theta^* := \theta$ mit $\phi(\theta^*) := \phi(\theta)$
6. Prüfung, ob keine zu evaluierende Lösungen mehr vorliegen, d. h. ob Liste $zuEvaluierten = \emptyset$
7. Sortierung der Liste $Population$ absteigend nach dem Zielfunktionswert $\phi(\cdot)$
8. Bereinigung der Nachbarschaften der in der Liste $Population$ enthaltenen Lösungen:
 - Lösung $\theta^1 :=$ beste Lösung der Liste $Population$, deren Nachbarschaft noch nicht bereinigt ist
 - Löschung aller folgenden Elemente θ^2 der sortierten Liste $Population$, die in der Nachbarschaft von θ^1 liegen, d. h. bei denen für mindestens die Hälfte der Variablen i gilt $|\theta_i^1 - \theta_i^2| \leq \bar{w}_i \cdot \bar{r}$
9. Prüfung, ob Nachbarschaften aller Elemente der Liste $Population$ bereinigt wurden
10. Herstellung der neuen Ausgangspopulation:
 - Ggf. Beschränkung der Liste $Population$ auf \bar{p} Elemente, bei Überschreitung Abschneiden des hinteren Teilstücks der Liste
 - Ggf. Auffüllung der Liste $Population$ mit zufällig bestimmten Lösungen $\theta \in \Theta$ mit $\phi(\theta) := -M$ (hinreichend kleine Zahl), bis maximale Populationsgröße \bar{p} erreicht ist
11. Variation einer Lösung der Population:
 - Lösung $\theta :=$ Kopie einer zufällig bestimmten Lösung der Liste $Population$
 - Zufällige Entscheidung für jede Variable θ_i in θ , ob zum Wert eine normalverteilte Zufallszahl $\mathcal{N}[0; \sigma]$ mit Standardabweichung $\sigma = (\bar{w}_i \cdot \bar{r})$ addiert wird, d. h. $\theta_i := \theta_i + \mathcal{N}[0; (\bar{w}_i \cdot \bar{r})]$
 - Hinzunahme der variierten Lösung θ zur Liste $zuEvaluierten$
12. Prüfung, ob Anzahl der neu erzeugten Variationslösungen bereits \bar{p} erreicht hat
13. Mutation einer Lösung der Population:
 - Lösung $\theta :=$ Kopie einer zufällig bestimmten Lösung der Liste $Population$
 - Zufällige Entscheidung für jede Variable θ_i in θ , ob diese mit einem zufälligen Wert innerhalb ihres Definitionsbereichs neu belegt wird oder ihren ursprünglichen Wert behält
 - Hinzunahme der mutierten Lösung θ zur Liste $zuEvaluierten$
14. Prüfung, ob Anzahl der neu erzeugten Mutationslösungen bereits \bar{p} erreicht hat
15. Kreuzung zweier Lösungen der Population:
 - Lösungen θ^1 und $\theta^2 :=$ Kopien zufällig bestimmter verschiedener Lösungen der Liste $Population$
 - Zufällige Entscheidung für jede Variable θ_i einer neuen Lösung θ , ob diese den Wert von θ_i^1 , θ_i^2 , oder einer Linearkombination beider Werte (Inter-/Extrapolation) annimmt
 - Hinzunahme der gekreuzten Lösung θ zur Liste $zuEvaluierten$
16. Prüfung, ob Anzahl der neu erzeugten Kreuzungslösungen bereits \bar{p} erreicht hat
17. Ende des Algorithmus: Präsentation der besten Lösung θ^* mit dem Zielfunktionswert $\phi(\theta^*)$

Wie in der Beschreibung des Ablaufs des Algorithmus ersichtlich wird, lassen sich die anzuwendenden evolutionären Operatoren jeweils separat auf einzelne Komponenten θ_i der Lösung beziehen, ohne dass eine Transformation bzw. Decodierung notwendig wäre.

Im Kontext der Anwendung des Evaluationskriteriums in Schritt 4 sei darauf hingewiesen, dass dieses nicht dazu dient, Lösungen bereits an dieser Stelle auszuschließen. Es wird lediglich entschieden, ob über die initial verwendeten \bar{S}_ϕ^{min} Replikationen hinaus weitere Replikationen notwendig sind, um die Bewertung der jeweiligen Lösung zu präzisieren und ggf. eine Ablösung der bisher besten Lösung zu ermöglichen.

Bei der Variation (Schritt 11) und der Mutation (Schritt 13) handelt es sich um unäre Operatoren, bei denen als Input lediglich eine Lösung verwendet wird, während die Kreuzung (Schritt 15) als binärer Operator zwei Lösungen als Input benötigt. Die Selektion der Eltern sowohl für die Variation, Mutation als auch Kreuzung erfolgt deren Rang in der sortierten Population entsprechend mit exponentiell abnehmender Wahrscheinlichkeit (vgl. [Eiben und Smith 2007], Kap. 3.7.2). Durch dieses Selektionsverfahren werden gute Lösungskandidaten bevorzugt ausgewählt, aber auch die schlechteren Kandidaten werden ab und zu selektiert. Dies verhindert eine zu schnelle Konvergenz auf Lösungen mit sehr guter Fitness und erhält so die Fähigkeit des Algorithmus zur Exploration. Durch die rangbasierte Auswahl werden möglicherweise verbleibende Unsicherheiten bei der Bewertung einzelner Lösungen weitgehend relativiert, da diese nur noch dann eine entscheidende Rolle spielen, wenn durch die unsichere Bewertung ein Tausch von Rängen ausgelöst wird.

Der Kreuzungsoperator aus Schritt 15 folgt der Idee des Scatter Search (vgl. Kap. 5.2.3.2) bzw. arithmetischer Kreuzungsoperatoren (vgl. [Michalewicz 1996], S. 112), indem er verschiedene Linearkombinationen der beiden Lösungen θ^1 und θ^2 bildet. Abbildung 38 illustriert das Vorgehen, bei dem zwischen die beiden betrachteten Lösungen mittels Interpolation drei äquidistante Punkte gelegt werden, zusätzlich wird über die bessere der beiden Lösungen (hier: θ^2) hinaus ein weiterer Punkt als Extrapolation mit identischem Abstand gebildet. Aus diesen sechs Punkten (einschließlich der ursprünglichen Punkte θ^1 und θ^2) wird je Variablenkomponente θ_i zufällig einer ausgewählt und aus diesen n Komponenten eine neue Lösung θ gebildet.




Abbildung 38: Kreuzung zweier Lösungen durch Inter- und Extrapolation

Quelle: eigene Darstellung

Innerhalb jeder Generation werden je Operator (Variation, Mutation und Kreuzung) entsprechend der Größe der Ausgangspopulation \bar{p} neue Lösungen generiert (vgl. Schritte 12, 14 und 16), sodass die resultierende Population auf eine Größe von insgesamt $4\bar{p}$ anwächst. Dem Selektionsmechanismus zur Auswahl der Folgepopulation wird eine Vorauswahl vorgeschaltet, deren Funktionsweise in Abbildung 39 dargestellt ist. Hierbei wird sukzessive eine von [Petrowski 1996] vorgeschlagene Bereinigung (*clearing*) der Nachbarschaft jeder

Lösung auf der vorab sortierten Population durchgeführt. Der Nachbarschaftsradius einer Lösung (entsprechend dem „clearing radius“ bei [Petrowski 1996]) wird durch ein Multiplum der Rasterschrittweite \bar{W} der Variablen mit einem vorgegebenen Nachbarschaftsskalierungsfaktor \bar{r} gebildet. So sind zwei Lösungen genau dann Nachbarn, wenn mindestens die Hälfte der Variablenkomponenten der beiden Lösungen einen Abstand von maximal $\bar{W}_i \cdot \bar{r}$ haben.

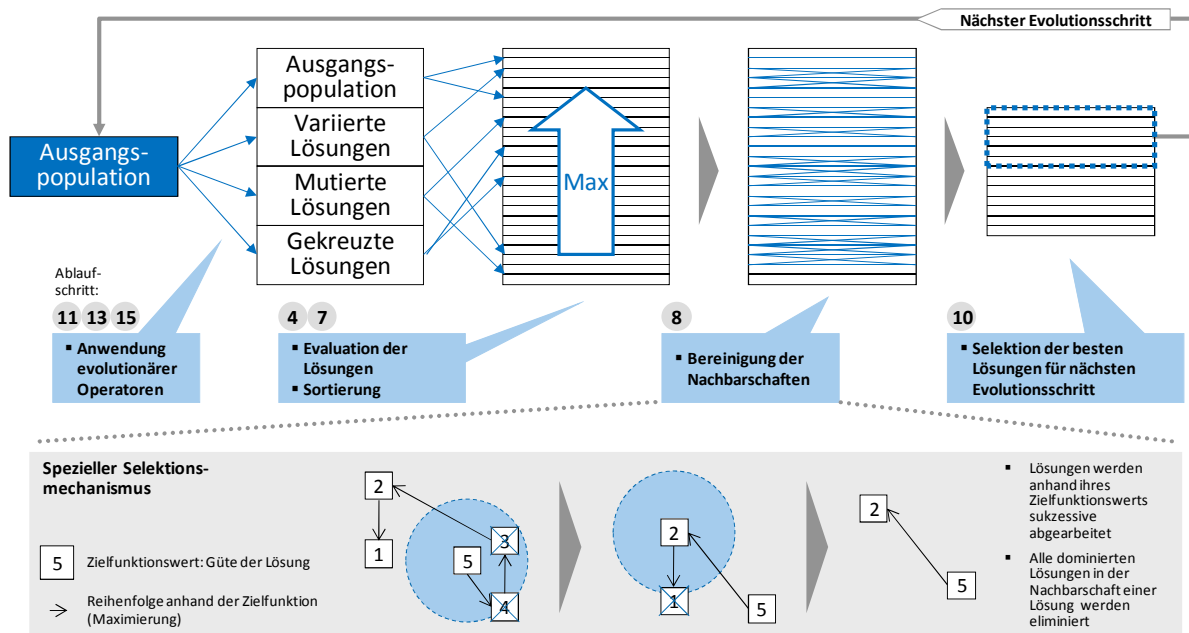


Abbildung 39: Selektionsmechanismus zur Auswahl der Folgepopulation

Quelle: eigene Darstellung

Die Evaluation jeder Lösung in Schritt 4 erfolgt mit dem auf Seite 104 beschriebenen Evaluationskriterium2. [Jin und Branke 2005] beschäftigen sich intensiv mit der Frage, wie mit stochastischen Zielfunktionsauswertungen im Kontext evolutionärer Algorithmen umgegangen werden kann. Der Nomenklatur dieser Autoren folgend entspricht der gewählte Ansatz einer expliziten Mittelwertbildung, wobei allerdings keine fixe Stichprobengröße verwendet wird, sondern diese adaptiv nach der Notwendigkeit zur Reduktion von Unsicherheit in der Bewertung der Stichprobe gesteuert wird.

6.2.5. Hybridalgorithmus aus NELS und SPSA

Sowohl der Algorithmus SPSA als auch der NELS zeigen sich bei den Untersuchungen später in Kapitel 7.4 als gut geeignet für die stochastische SBO, speziell auch für Problemstellungen mit den in Kapitel 6.1 analysierten typischen Charakteristika einer ABS. Ihre Stärken haben beide Verfahren jedoch an unterschiedlichen Stellen, während der NELS als populationsbasierter Algorithmus strukturell eher für die Globaloptimierung prädestiniert ist, sind die Wurzeln des SPSA in der Lokaloptimierung zu finden. Entsprechend waren Anpassungen an den jeweiligen Verfahren notwendig, um diesen sowohl Fähigkeiten zur Diversifikation als auch zur Intensivierung zu gegeben. Alternativ hierzu können beiden Verfahren unter Beibehaltung ihrer spezifischen Vorteile in einem sog. Hybridalgorithmus (vgl. [Eiben und Smith 2007], Kap 10.4.3) verknüpft werden. Die Kombination dieser beiden State-

of-the-art-Verfahren in einer Metaheuristik könnte, so die Idee, den Überlegungen von [Andradottir und Prudius 2009] folgend eine ausgewogene Mischung zwischen Global- und Lokalsuche herstellen, die gegenüber den einzelnen Verfahren überlegen ist. Auch [Spall 2003] (S. 249) skizziert eine so kombinierte Metaheuristik als prinzipiell erfolgversprechend. In seinen Grundzügen entspricht dieses Hybridverfahren einem Scatter Search (vgl. Kap. 5.2.3.2), auch dort wird ein mengenbasiertes Optimierungsverfahren mit einer lokalen Verbesserungskomponente kombiniert, welche in der vorliegenden Arbeit jedoch durch den SPSA als ein Best-in-class-Verfahren zur stochastischen SBO gebildet wird. Auch [Ning et al. 2005] verfolgen die Idee einer Kombination aus evolutionärem Algorithmus und SPSA, die dem Ablauf nach stark dem hier vorgestellten Verfahren ähnelt.

Die Kombination der beiden Verfahren NELS und SPSA funktioniert dergestalt, dass bei jedem Generationswechsel des NELS mehrere Lösungskandidaten zufällig aus der Population ausgewählt, mit einigen Iterationen des SPSA-Algorithmus lokal optimiert und abschließend der Ausgangspopulation für die folgende Generation hinzugefügt werden. Da der SPSA jeweils nur für eine eng begrenzte Anzahl Iterationen läuft, sind Ausbruchsfunktionen wie in Schritt 3 und 5 des in Kapitel 6.2.3 spezifizierten Algorithmus hierbei nicht erforderlich. Neben der beabsichtigten lokalen Verbesserung der mit dem SPSA weiterentwickelten Lösungen erzeugt der Hybridalgorithmus zusätzlich eine zielgerichtete Diversifikation der Population im Umkreis guter Lösungen.

Dieses Verfahren stellt in der von [Sinha und Goldberg 2003] entwickelten Klassifikation evolutionärer Hybridalgorithmen einen Algorithmus dar, der zum Zweck der Diversifikation („exploitation“) sequenziell gestuft hybridisiert wurde („pipelined, staged“), und der als Sekundärmethode neben dem evolutionären Algorithmus eine Intensivierung („local search“) mittels dem Algorithmus SPSA durchführt. Die Autoren identifizieren in dem genannten Report zwar eine Vielzahl geeigneter Sekundärverfahren für die Hybridisierung, der SPSA bleibt dort jedoch unerwähnt.

Die konkrete Implementierung dieses Algorithmus ist in Abbildung 40 dargestellt. Die darauffolgende Anleitung baut zur einfacheren Nachvollziehbarkeit auf den Ausführungen zu den Algorithmen NELS (S. 135 f.) und SPSA (S. 130 f.) auf, lediglich auf Abweichungen hierzu sei explizit eingegangen:

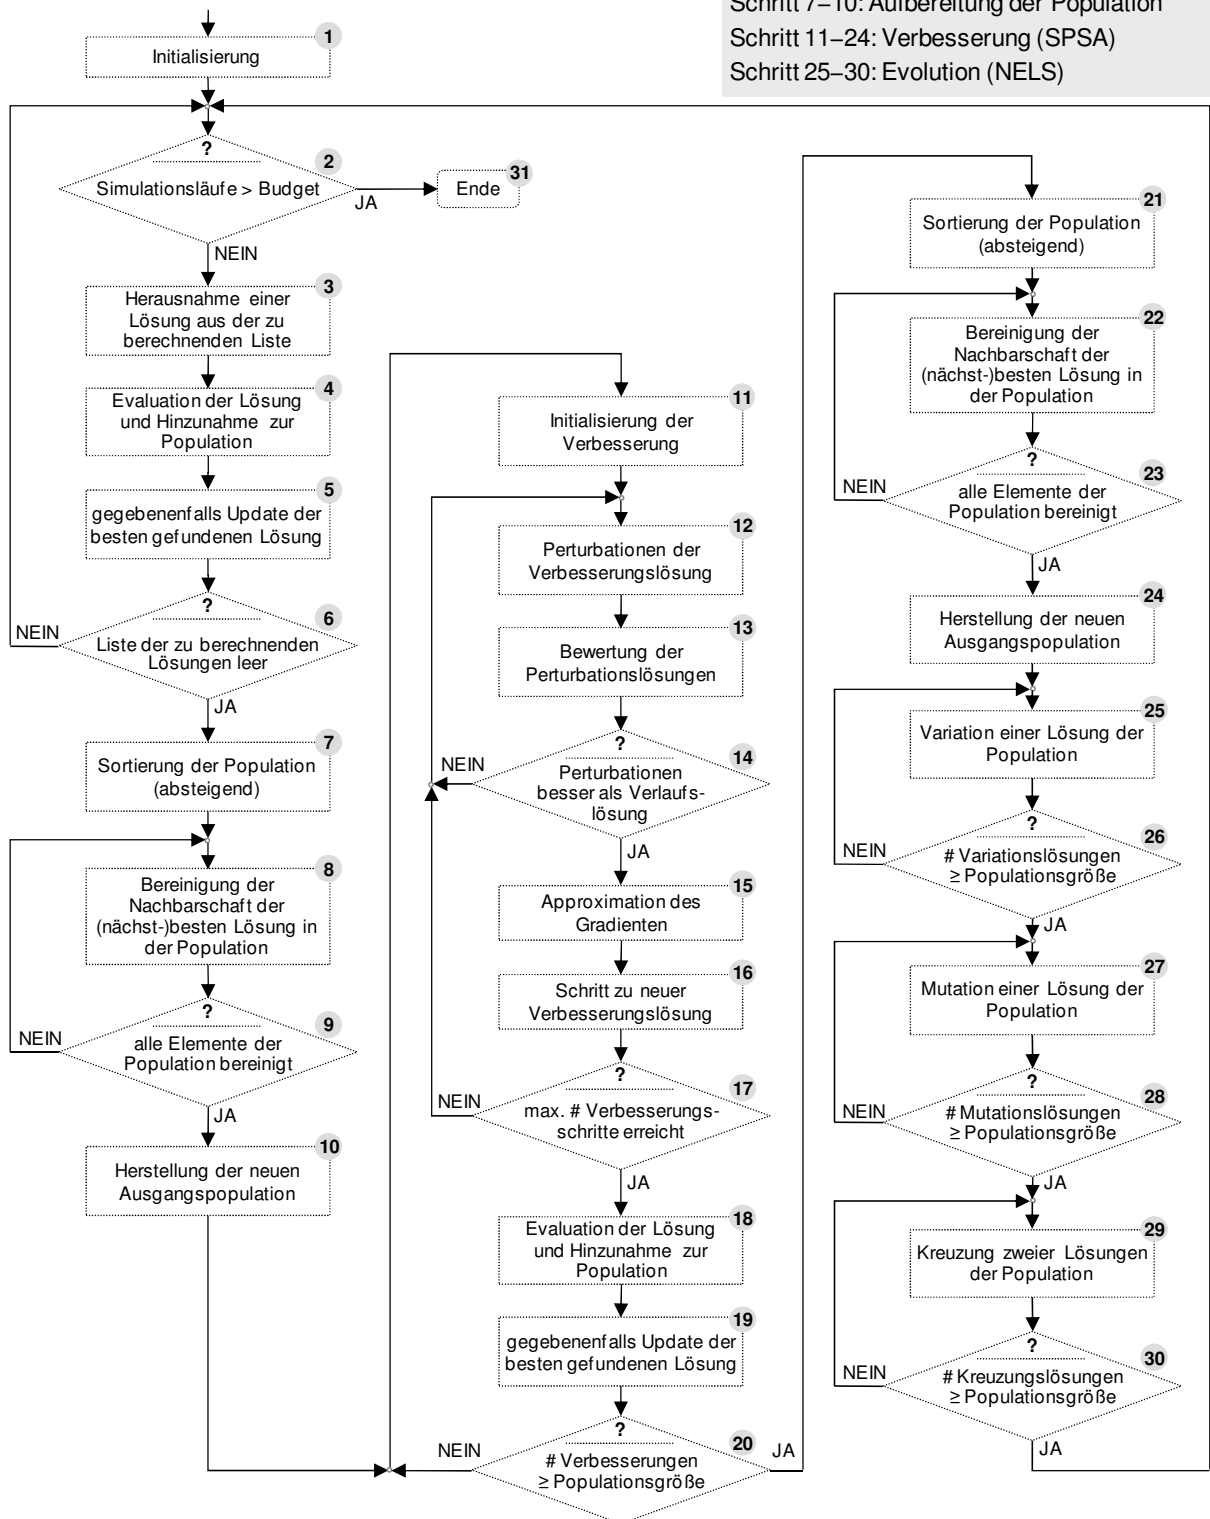


Abbildung 40: Ablaufdiagramm des Algorithmus „Hybrid NELS-SPSA“

Quelle: eigene Darstellung

Ablauf des Algorithmus „Hybrid NELS-SPSA“ (Formulierung für ein Maximierungsproblem)

Gegeben: NELS und SPSA-Parameterwerte; Parameterwert für die Anzahl der Verbesserungsschritte \bar{v}

1. Initialisierung:
 - analog zu NELS Schritt 1
 - Zähler der SPSA-Verbesserungsschritte $j := 0$
2. bis 10. analog zu NELS Schritt 2–10
11. Initialisierung der Verbesserung:
 - Lösung $\theta :=$ Kopie einer zufällig bestimmten Lösung der Liste *Population*
 - Zähler der SPSA-Verbesserungsschritte $j := j + 1$
12. bis 13. analog zu SPSA Schritt 3–4
14. bis 16. analog zu SPSA Schritt 6–8
17. Prüfung, ob max. Anzahl der SPSA-Verbesserungsschritte für diese Lösung erreicht ist, d. h., ob $j \geq \bar{v}$
18. Evaluation der Lösung und Hinzunahme zur Population
 - Zähler der SPSA-Verbesserungsschritte zurücksetzen $j := 0$
 - analog zu SPSA Schritt 10
 - Hinzunahme der Lösung θ zur Liste *Population*
19. analog zu SPSA Schritt 11
20. Prüfung, ob Anzahl der verbesserten Lösungen bereits \bar{p} erreicht hat
21. bis 31. analog zu NELS Schritt 7–17

Die Selektion der Eltern für die Variation (Schritt 25), Mutation (Schritt 27) und Kreuzung (Schritt 29) erfolgt hierbei im Gegensatz zum ursprünglichen NELS nicht rangbasiert, sondern gleichverteilt zufällig. Eine Bevorzugung der besten Lösungen der Population ist nicht notwendig, da durch die SPSA-Verbesserungsschritte bereits eine verstärkte Intensivierung im Umkreis der besten Lösungen stattfindet.

6.3. Demonstration der Verfahren

Um die Funktionsweise der vorgestellten Verfahren greifbarer zu machen, werden die Algorithmen in teilweise vereinfachter Form im Folgenden jeweils auf ein beispielhaftes Optimierungsproblem angewendet. Hierzu sei die bekannte zweidimensionale Rastrigin-Testfunktion verwendet, definiert durch $f(\theta_1; \theta_2) = 80 - \theta_1^2 - \theta_2^2 + 10 \cdot \cos(2\theta_1) + 10 \cdot \cos(2\theta_2)$, für die im Rahmen der Optimierung eine maximale Lösung gefunden werden soll. Wie man auf dem Plot der Funktion in Abbildung 41 erkennt, hat diese mehrere lokale Maxima, wobei sich das globale Maximum bei $\theta_1 = \theta_2 = 0$ befindet mit $f(0; 0) = 100$. Der Suchraum für beide Variablen sei das Intervall $[-5; 5]$, auf dem sich acht lokale Maxima sowie das globale Maximum der Funktion befinden. Der Einfachheit halber ist diese Testfunktion deterministisch gewählt, entsprechend werden auch keine mehrfachen Replikationen oder ein darauf aufbauendes Evaluationskriterium für die Auswertung benötigt. Pro Verfahren werden einige Iterationen im Detail dargestellt. Bei einem vollständigen Optimierungslauf würde man diese Schritte so lange wiederholen, bis das vorgegebene Budget an Zielfunktionsauswertungen aufgebraucht ist. Die bis dahin beste gefundene Lösung θ^* mit dem maximalen Zielfunktionswert $f(\theta^*)$ wäre schließlich das Ergebnis des Optimierungslaufs.

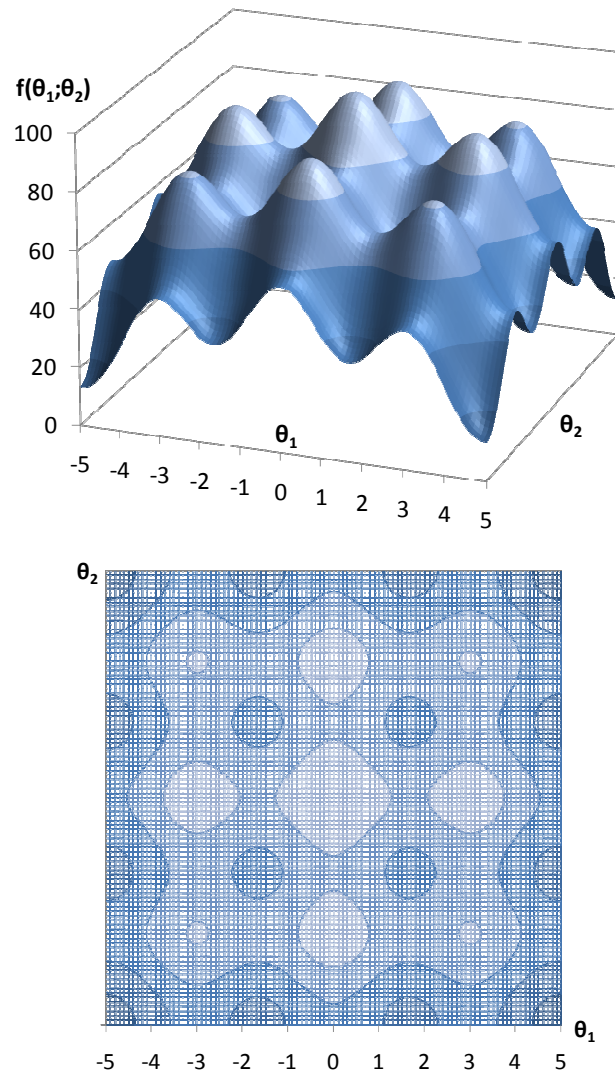


Abbildung 41: Plot der Rastrigin-Testfunktion

Quelle: eigene Berechnung und Darstellung

Die Funktionsweise des Global Random Search (siehe Kapitel 6.2.1) ist schnell demonstriert, hierbei werden sukzessive neue Lösungen innerhalb des Suchraumes zufällig generiert und überprüft. Beispielsweise startet der Algorithmus mit der zufälligen Lösung $\theta^1 = (3,91; -1,02)$, die einen Zielfunktionswert $f(\theta^1) = 59,49$ hat. Damit ist θ^1 die beste bis dahin gefundene Lösung, also gilt $\theta^* := \theta^1$. Als nächste zu überprüfende Lösung wird $\theta^2 = (2,63; -4,80)$ zufällig ausgewählt mit $f(\theta^2) = 45,40$. Da $f(\theta^2) < f(\theta^1)$ ist, ändert sich die beste Lösung θ^* nicht. Als nächste zufällige Lösung wird $\theta^3 = (-2,46; -1,89)$ betrachtet mit $f(\theta^3) = 64,41$. Es gilt $f(\theta^3) > f(\theta^*)$, somit wird $\theta^* := \theta^3$ die neue beste gefundene Lösung.

Da die Funktionsweise des kommerziellen Optimierungsverfahrens OptQuest (siehe Kapitel 6.2.2) im Detail nicht veröffentlicht ist, muss auf eine Demonstration der Funktionsweise dieses Verfahrens leider verzichtet werden.

Der evolutionäre Algorithmus NELS (siehe Kapitel 6.2.4) startet auf einer Population zufällig gewählter Lösungen. Zur Demonstration seien dies die drei oben im Kontext des GRS genannten Lösungen θ^1 , θ^2 und θ^3 als Ausgangspopulation mit der daraus besten Lösung $\theta^* = \theta^3$. Aus der Population wird Lösung θ^2 zufällig ausgewählt und durch Variation mit einer normalverteilten Zufallsvariablen $N[\mu; \sigma]$ zur neuen Lösung θ^4 modifiziert, wobei jeweils $\theta_1^4 = \theta_1^2 + N[0; 1]$ und $\theta_2^4 = \theta_2^2 + N[0; 1]$ gelten. Mit den Werten 0,37 und 0,61 als Realisationen der Zufallsvariablen ergibt sich die neue Lösung $\theta^4 = (3,00; -4,19)$ mit $f(\theta^4) = 58,02$. Da $f(\theta^4) < f(\theta^*) = 64,41$ ist, hat die Variation nicht zu einer neuen besten Lösung geführt, die Lösung θ^4 wird also lediglich zur bestehenden Population hinzugefügt. Für die Mutation wird zufällig Lösung θ^3 ausgewählt. Ebenfalls zufällig wird entschieden, dass die erste Komponente der Lösung $\theta_1^3 = -2,46$ für die neue Lösung θ^5 unverändert übernommen wird, während die zweite Komponente durch eine Zufallszahl innerhalb des Definitionsbereichs ersetzt (d. h. mutiert) wird: $\theta_2^5 = 3,45$. Dadurch ergibt sich $\theta^5 = (-2,46; 3,45)$ mit $f(\theta^5) = 72,26$. Diese Lösung wird ebenfalls der Population hinzugefügt, zusätzlich wird aufgrund von $f(\theta^5) > f(\theta^*)$ die beste Lösung zu $\theta^* = \theta^5$ aktualisiert. Schließlich werden für die Kreuzung zufällig die Lösungen θ^1 und θ^2 aus der Population ausgewählt. Ebenso zufällig wird für die erste Komponente der neuen Lösung θ^6 entschieden, dass diese eine gleichgewichtete Linearkombination der beiden Vaterlösungen darstellt $\theta_1^6 = (\theta_1^1 + \theta_1^2)/2$, während die zweite Komponente diese beiden Lösungen im Verhältnis 1:3 gewichtet. Die so konstruierte Lösung $\theta^6 = (3,27; -3,86)$ hat einen Zielfunktionswert $f(\theta^6) = 65,42$ und stellt aufgrund von $f(\theta^6) < f(\theta^*)$ keine neue beste Lösung dar, wird also ebenfalls lediglich der Population hinzugefügt. Die nun durchzuführende Bereinigung der Nachbarschaften der Population startet mit deren Sortierung: $\theta^5 > \theta^6 > \theta^3 > \theta^1 > \theta^4 > \theta^2$. Lösung θ^5 dominiert die Lösung θ^3 und liegt in deren Nachbarschaft, da $|\theta_1^5 - \theta_1^3|$ kleiner ist als der definierte Nachbarschaftsradius von 0,5. Somit wird θ^3 aus der Population gelöscht. Ebenso eliminiert θ^6 die dominierte Lösung θ^4 in ihrer Nachbarschaft. Darüber hinaus finden sich keine dominierten Lösungen in den jeweiligen Nachbarschaften, somit verbleiben θ^5 , θ^6 , θ^1 und θ^2 in der Population. Da die Größe der Population vor Beginn der nächsten Iteration auf ihre ursprüngliche Größe gekürzt werden muss, wird die schlechteste Lösung θ^2 ebenfalls gelöscht, sodass die Ausgangspopulation für die nächste NELS-Iteration aus θ^5 , θ^6 und θ^1 besteht.

Der SPSA (siehe Kapitel 6.2.1) startet zur Demonstration ebenso wie der GRS auf der zufälligen Verlaufslösung $\theta^1 = (3,91; -1,02)$ mit dem Zielfunktionswert $f(\theta^1) = 59,49$ und $\theta^* = \theta^1$. Mit dem Skalierungsfaktor $\bar{\lambda} = 10$, einem als konstant angenommenen Koeffizienten $c = 0,01$ und einem für die erste Iteration zufällig aus einer Bernoulli ± 1 Verteilung gewählten Perturbationsvektor $\rho_1 = (-1; 1)$ ergeben sich die Schrittweite $\Delta_1^c = (-0,1; 0,1)$ und damit die beiden Perturbationslösungen $\theta^1 \pm \Delta_1^c$, also $\theta^{1+} = (3,81; -0,92)$ mit $f(\theta^{1+}) = 64,30$ und $\theta^{1-} = (4,01; -1,12)$ mit $f(\theta^{1-}) = 54,81$. Hieraus lässt sich der Gradient $g_1 = (64,30 - 54,81)/(2 \cdot \Delta_1^c) = (-47,45; 47,45)$ approximieren. Mit einem als konstant angenommenen Koeffizienten $a = 0,0001$ berechnet sich die Schrittweite $\Delta_1^A = (-0,47; 0,47)$ und die neue Verlaufslösung $\theta^2 = \theta^1 + \Delta_1^A = (3,44; -0,55)$ mit $f(\theta^2) = 80,67$. Da $f(\theta^2) > f(\theta^*)$ gilt, ist eine neue beste Lösung $\theta^* = \theta^2$ gefunden. Für die zweite Iteration

wird der Perturbationsvektor $\boldsymbol{\rho}_2 = (1; -1)$ aus der Bernoulliverteilung gezogen, somit gilt $\Delta_2^C = (0,1; -0,1)$. Es ergeben sich $\boldsymbol{\theta}^{2+} = (3,54; -0,65)$ mit $f(\boldsymbol{\theta}^{2+}) = 76,71$ und $\boldsymbol{\theta}^{2-} = (3,34; -0,45)$ mit $f(\boldsymbol{\theta}^{2-}) = 84,08$. Somit lässt sich ein Gradient in der Verlaufslösung von $\boldsymbol{g}_2 = (-36,85; 36,85)$ approximieren, was eine Schrittweite von $\Delta_2^A = (-0,18; 0,18)$ und damit eine neue Verlaufslösung $\boldsymbol{\theta}^3 = (3,26; -0,37)$ mit $f(\boldsymbol{\theta}^3) = 86,34$ ergibt. Diese Lösung ersetzt abermals die bisher beste Lösung $\boldsymbol{\theta}^* := \boldsymbol{\theta}^3$. Für die dritte Iteration wird der Perturbationsvektor $\boldsymbol{\rho}_3 = (1; 1)$ gezogen, somit ist $\Delta_3^C = (0,1; 0,1)$. Es ergeben sich $\boldsymbol{\theta}^{3+} = (3,36; -0,27)$ mit $f(\boldsymbol{\theta}^{3+}) = 86,28$ und $\boldsymbol{\theta}^{3-} = (3,16; -0,47)$ mit $f(\boldsymbol{\theta}^{3-}) = 85,68$. Somit lässt sich ein Gradient in der Verlaufslösung von $\boldsymbol{g}_3 = (-3,00; 3,00)$ approximieren, was eine Schrittweite von $\Delta_3^A = (0,02; 0,02)$ und damit eine neue Verlaufslösung $\boldsymbol{\theta}^4 = (3,28; -0,35)$ mit $f(\boldsymbol{\theta}^4) = 86,39$ ergibt. Diese Lösung ersetzt abermals die bisher beste Lösung $\boldsymbol{\theta}^* := \boldsymbol{\theta}^4$, allerdings ist die Verbesserung mit 0,05 gegenüber der bisher besten Lösung $\boldsymbol{\theta}^3$ stark rückläufig. Der Algorithmus nähert sich bereits dem lokalen Maximum bei $(2,99; 0,00)$, welches er aufgrund der hier zur Vereinfachung angenommenen konstanten Schrittweite aber immer wieder von wechselnden Seiten überspringen würde, anstatt dort zu konvergieren. Da keine Verbesserung mehr erzielt wird, greift nach einigen erfolglosen Iterationen die erste Stufe der Ausbruchregeln, welche die Schrittweiten variabler gestaltet. Durch den großen Abstand des erreichten lokalen Maximums vom globalen Maximum wird aber auch hierdurch keine neue beste Lösung erzielt.

Die Demonstration des Hybridalgorithmus aus NELs und SPSA (siehe Kapitel 6.2.5) setzt auf der bereits gezeigten NELs-Iterationen auf, welche auch beim Hybridalgorithmus analog vollzogen wird. Die übrig gebliebene Population besteht aus den Lösungen $\boldsymbol{\theta}^1 = (3,91; -1,02)$ mit dem Zielfunktionswert $f(\boldsymbol{\theta}^1) = 59,49$, $\boldsymbol{\theta}^5 = (-2,46; 3,45)$ mit $f(\boldsymbol{\theta}^5) = 72,26$ und $\boldsymbol{\theta}^6 = (3,27; -3,86)$ mit $f(\boldsymbol{\theta}^6) = 65,42$. Anstatt die nächste Iteration des NELs zu beginnen, wird aus dieser Population zufällig die Lösung $\boldsymbol{\theta}^5$ ausgewählt und mit zwei SPSA-Schritten unter Verwendung der zufällig gewählten Perturbationsvektoren $(-1; 1)$ und $(1; 1)$ versucht, diese Lösung zu verbessern. Es ergibt sich die neue Lösung $\boldsymbol{\theta}^7 = (-2,58; 3,25)$ mit $f(\boldsymbol{\theta}^7) = 76,88$, welche zur Population hinzugefügt wird. Analog wird aus der Lösung $\boldsymbol{\theta}^1$ mit den Perturbationsvektoren $(1; -1)$ sowie $(1; -1)$ die neue Lösung $\boldsymbol{\theta}^8 = (3,26; -0,37)$ und aus der Lösung $\boldsymbol{\theta}^6$ unter Anwendung der Perturbationsvektoren $(-1; -1)$ sowie $(1; -1)$ die neue Lösung $\boldsymbol{\theta}^9 = (3,22; -3,49)$ erzeugt, mit den Zielfunktionswerten $f(\boldsymbol{\theta}^8) = 86,34$ und $f(\boldsymbol{\theta}^9) = 75,00$. Aufgrund von $f(\boldsymbol{\theta}^8) > f(\boldsymbol{\theta}^*)$ wird die beste Lösung zu $\boldsymbol{\theta}^* := \boldsymbol{\theta}^8$ aktualisiert. Die Sortierung der gesamten resultierenden Population ergibt $\boldsymbol{\theta}^8 > \boldsymbol{\theta}^7 > \boldsymbol{\theta}^9 > \boldsymbol{\theta}^5 > \boldsymbol{\theta}^6 > \boldsymbol{\theta}^1$. Da sowohl $\boldsymbol{\theta}^9$ als auch $\boldsymbol{\theta}^6$ in der Nachbarschaft von $\boldsymbol{\theta}^8$ liegen und von dieser Lösung dominiert werden, müssen beide Lösungen aus der Population bereinigt werden. Gleiches gilt für die Lösung $\boldsymbol{\theta}^5$, da diese von $\boldsymbol{\theta}^7$ dominiert wird. Übrig bleiben die Lösungen $\boldsymbol{\theta}^8$, $\boldsymbol{\theta}^7$ und $\boldsymbol{\theta}^1$ als Ausgangspopulation für die nächste NELs-Iteration, worauf abermals SPSA-Schritte zur potenziellen Verbesserung durchgeführt werden.

7. Experimenteller Vergleich der Verfahren zur simulationsbasierten Optimierung

Im Folgenden werden die bereits in Kapitel 6.2 vorgestellten Verfahren NELLS, SPSA und der Hybridalgorithmus NELLS-SPSA einem quantitativen Vergleich unterzogen, um deren Leistungsfähigkeit speziell für die Optimierung der Parameter einer ABS zu analysieren. Als Benchmarks dient zum einen der Global Random Search, dieser Algorithmus repräsentiert als reine Zufallssuche die untere Grenze für effiziente Lösungsverfahren. Eher am oberen Ende der Leistungsskala angesiedelt ist zum anderen das kommerzielle Optimierungspaket OptQuest, dieses Verfahren stellt aufgrund seiner bekannten Leistungsfähigkeit einen kompetitiven Vergleichsmaßstab dar.

7.1. Versuchsaufbau

Leider gestaltet sich die Auswahl repräsentativer Testprobleme für den Vergleich von Algorithmen zur SBO schwierig, da sich für die SBO noch keine diesbezüglichen Standards etabliert haben (vgl. [Fu 2002]), schon gar nicht für den Spezialfall der Optimierung einer ABS. Als exemplarische experimentelle Fallstudie sei deshalb die in Kapitel 4 entworfene ABS des deutschen Mobilfunkmarktes verwendet, wobei zur Vereinfachung die im Modell abgebildeten Kunden auf 250 Agenten beschränkt sind. Hierdurch wird die Laufzeit eines Simulationslaufs ohne Aufbereitung der grafischen Oberfläche auf nur noch ca. eine Sekunde verkürzt, ohne dass sich die Problemstellung strukturell signifikant ändert. Als freie Parameter der Simulation sind die Preiskomponenten der Tarifportfolios der beiden Anbieter \mathbb{C} und \mathbb{D} modelliert, sodass die Simulation, wie in Tabelle 8 aufgelistet, insgesamt zehn freie Parameter mit den Ober- (\bar{O}) und Untergrenzen (\bar{U}) sowie den Rasterschrittweiten (\bar{W}) aufweist.

Parameter	Einheit	\bar{U}	\bar{O}	\bar{W}
\mathbb{C} Vertrag Minutenpreis	€/min	0	1	0,01
\mathbb{C} Vertrag Grundgebühr	€	0	50	0,2
\mathbb{C} Vertrag Inklusivminuten	min	0	60	5
\mathbb{C} Zeit Minutenpreis	€/min	0	1	0,01
\mathbb{C} Pauschal Grundgebühr	€	0	50	0,2
\mathbb{D} Vertrag Minutenpreis	€/min	0	1	0,01
\mathbb{D} Vertrag Grundgebühr	€	0	50	0,2
\mathbb{D} Vertrag Inklusivminuten	min	0	60	5
\mathbb{D} Zeit Minutenpreis	€/min	0	1	0,01
\mathbb{D} Pauschal Grundgebühr	€	0	50	0,2

Tabelle 8: Freie Parameter der Simulation

Quelle: eigene Darstellung

Der Raum der Parameter ist hierbei konvex, d. h., alle Linearkombinationen zulässiger Parameterwerte sind ebenfalls zulässig. Die auf die Parameter bezogenen Variablen der

Optimierung sind kontinuierlich modelliert, wobei die vorgegebenen Unter- und Obergrenzen der Parameter den Definitionsbereich Θ des Optimierungsproblems festlegen. Die Rasterschrittweite dient lediglich der exogenen Kalibrierung der Schrittweiten und Nachbarschaften im Lösungsraum. Für die praktische Verwertung einer kontinuierlichen Lösung müsste deshalb noch eine Projektion (vgl. Kap. 5.2) auf das Raster der zulässigen Parameterwerte erfolgen, was jedoch nicht im Fokus des folgenden Algorithmenvergleichs steht.

Um eine exemplarische Problemstellung mit hochdimensionalem Optimierungsraum zu erhalten, sei als Zielsetzung die Kollaboration der Anbieter \mathbb{C} und \mathbb{D} betrachtet – mit dem Zweck, möglichst hohe, aber auch ausgeglichene Umsätze durch eine Zusammenarbeit bei der Preisgestaltung zu erzielen. Die Zielfunktion summiert entsprechend die periodischen Umsätze der beiden Anbieter über den betrachteten Simulationszeitraum von 36 Perioden, wobei eine Differenz der summierten Umsätze von Anbieter \mathbb{C} und \mathbb{D} durch den Abzug von drei Viertel dieser Differenz vom Zielfunktionswert „bestraft“ wird.

Bei der Implementierung der Simulation wird ein von der Optimierung separierter Zufallszahlengenerator eingesetzt, der jeweils die Zufallszahlen für alle Zufallsvariablen der Simulation gemeinsam bereitstellt. Dies ermöglicht die Verwendung von *Common random numbers* (vgl. [Spall 2003], Kap. 14.4) zur Reduktion der Variabilität zwischen der Evaluation verschiedener Lösungen. Hierbei wird ein korreliertes Sampling durchgeführt, bei dem für die m -te Replikation jeder Lösung der Zufallszahlengenerator der Simulation mit der Zahl m als Saat initialisiert wird, folglich also für identische Replikationsnummern identische Zufallszahlen für die Simulation liefert (vgl. [Goldsman und Nelson 1998]). So wird mit einer gegebenen Saat ein deterministisches *Szenario* der Simulation festgelegt. Die Simulation ist synchronisiert, sodass bei der Auswertung verschiedener Lösungskandidaten immer an identischen, deterministisch vorgegebenen Stellen im Ablauf der Simulation Zufallszahlen gezogen werden. Die gemeinsamen Zufallszahlen resultieren also in einem identischen Wert der Zielfunktionsauswertung für identische Lösungen θ . Dies gilt sowohl für den Zielfunktionswert einzelner Replikationen $\phi(\theta, \bar{y})$ als auch für den Stichproben-Mittelwert mehrerer Replikationen $\mu = \frac{1}{m} \cdot \sum_{i=1}^m \phi_i(\theta, \bar{y}_i)$, sofern zur Berechnung eine identische Anzahl m an Replikationen verwendet wurde. Dieses Konzept ist somit vergleichbar mit der Sample-Path-Optimierung (vgl. Kap. 5.2.1), bei der ebenfalls durch eine vorgegebene Belegung der Zufallsvariablen der Simulation eine Zusammenstellung an deterministischen Ersatzmodellen (analog zu Szenarien) getroffen wird. Obwohl die Auswahl der Zufallszahlen bzw. deren Saaten über die Simulation verschiedener Lösungen hinweg nicht mehr unabhängig ist, stellt dieses Vorgehen dennoch keine praktische Einschränkung für die angenommene Unabhängigkeit der Zufallszahlen innerhalb der jeweiligen Simulation dar.

Potenziell soll der Einsatz von Common random numbers wie in [Spall 2003] (Kap. 14.4) gezeigt dazu dienen, die Vergleichbarkeit zwischen evaluierten Lösungen durch den Einsatz korrelierter Rahmenbedingungen zu erhöhen. Der in Kapitel 5.1 beschriebene stochastische Störterm $\varepsilon(\theta, \bar{y})$ in der Zielfunktion der Simulationsauswertung einer Lösung, der über \bar{y} direkt von der gewählten Saat abhängig ist, weist zwischen verschiedenen Lösungen in der Tat potenziell eine Korrelation auf. Folglich kann dieses Verfahren dazu dienen, die Varianz

zwischen der Evaluation mehrerer Lösungen zu reduzieren. Auch für den Vergleich verschiedener Optimierungsalgorithmen ist dies vorteilhaft, da jede Optimierung so auf einer identischen Menge deterministischer Simulationsszenarien arbeitet, unabhängig vom eingesetzten Algorithmus. Im betrachteten Fall der ABS ist der positive Effekt der Common random numbers aufgrund der inhärenten Komplexität der Simulation allerdings erwartungsgemäß nicht signifikant ausgeprägt, gleichwohl stellt der Ansatz aber zumindest auch keine Einschränkung und keinen negativen Einfluss dar.

Die Testproblemstellung ist beliebig gewählt, es handelt sich dabei um einen abstrahierten Anwendungsfall mit den typischen Problemcharakteristika einer ABS (vgl. Kap. 6.1). Keines der betrachteten Verfahren weist a priori einen selektiven Vorteil oder Nachteil bezüglich der Testproblemstellung auf. Durch die unterschiedlichen Saaten des Zufallsgenerators der Simulation werden unterschiedliche Ausprägungen dieses Anwendungsfalls zufällig konstruiert.

Bei einer Evaluation von 50.000 zufällig innerhalb des Definitionsbereichs gewählten Lösungen jeweils mit 500 Replikationen und einer Einteilung der resultierenden Zielfunktionswerte in Klassen mit einer Breite von 10.000 („10k“) ergibt sich das in Abbildung 42 gezeigte Histogramm, welches den geringen Umfang guter Lösungen verdeutlicht – nur 1,54 % der Lösungen hat eine Bewertung von größer als 150.000, sogar lediglich 0,18 % haben einen Zielfunktionswert von größer als 200.000.




Abbildung 42: Histogramm vieler zufälliger Lösungen

Quelle: eigene Berechnung und Darstellung

Auf Basis der identischen simulierten Grundgesamtheit zeigt Abbildung 43 ein weiteres Charakteristikum der betrachteten Simulation: Die Bandbreite der Zielfunktionswerte einer konkreten Lösung, welche durch unterschiedliche Saaten des Zufallsgenerators der Simulation entstehen können, wächst mit der Güte der Lösung. Speziell für die bei der Optimierung gesuchten besten Lösungen ist die Bandbreite und analog die Varianz der Zielfunktionswerte vergleichsweise groß. Für den Vergleich der Optimierungsverfahren ist dies

durchaus eine gewünschte Eigenschaft des Testproblems, da sie die Optimierung weiter erschwert und so Möglichkeiten zur Differenzierung der Leistungsfähigkeit unterschiedlicher Verfahren bietet. Im praktischen Anwendungsfall ist eine hohe Bandbreite hingegen nicht wünschenswert, kann aber auch recht einfach z. B. mit dem sogenannten (μ, σ) -Ansatz (vgl. [Klein und Scholl 2004], Kap. 8.2.2.2) durch Reduzierung des durchschnittlichen Zielfunktionswerts mehrerer Replikationen um einen Anteil ihrer Varianz vermieden werden.




Abbildung 43: Bandbreite der stochastischen Zielfunktionsauswertungen

Quelle: eigene Berechnung und Darstellung

Übergreifend für alle Algorithmen und Experimente seien folgende Parameterwerte vorgegeben: die Mindestanzahl Replikationen $S^{min} = 20$, die Höchstanzahl Replikationen $S^{max} = 500$, das Konfidenzniveau $(1 - \alpha) = 0,98$ und das Simulationsbudget $\bar{S} = 50.000$. Die Mindestanzahl der Replikationen S^{min} je untersuchter Lösung stellt einen üblichen Wert aus der Literatur dar (vgl. S. 98), die Höchstanzahl S^{max} hingegen wurde empirisch anhand der Varianz unterschiedlicher Lösungen mit dem Ziel ermittelt, eine problemadäquate Begrenzung der Unsicherheit bei der Bewertung einer Lösung zu erreichen. Das Konfidenzniveau $(1 - \alpha)$ ist ebenfalls mit einem häufig in der Literatur verwendeten Wert vorgegeben. Die Größe des Simulationsbudgets \bar{S} je Optimierungslauf wurde anhand initialer Tests so ermittelt, dass die Algorithmen nach Verbrauch dieses Budgets in der Regel keine signifikante Verbesserung mehr erzielen.

Als Werte für die Standardparameter des Algorithmus SPSA werden $\bar{a} = 0,00002$, $\bar{A} = 5.000$, $\bar{c} = 0,1$, $\bar{\alpha} = 0,602$ und $\bar{\gamma} = 0,101$ verwendet. Die Werte für \bar{a} und \bar{c} sind hierbei empirisch ermittelt. \bar{A} ist nach [Spall 2003] (S. 190) berechnet. Die Werte für $\bar{\alpha}$ und $\bar{\gamma}$ entstammen der allgemeinen Empfehlung für den SPSA, siehe [Spall 1998a] oder [Spall 2003] (S. 190). Zusätzlich fließt bei der Berechnung der Schrittweiten Δ_t^A und Δ_t^C der problemspezifische Skalierungsfaktor $\bar{\lambda} = \bar{\mathbf{O}} - \bar{\mathbf{U}}$ mit ein, um die unterschiedlichen Größenordnungen der Variablen im Lösungsraum zu berücksichtigen.

Als Parameterwerte für den Algorithmus NELS werden eine Populationsgröße $\bar{p} = 20$ und ein Nachbarschaftsskalierungsfaktor $\bar{r} = 2$ angenommen, beide sind empirisch ermittelt.

Als Parameterwert für den Hybridalgorithmus wird zusätzlich zu den genannten Werten für SPSSA und NELS eine Anzahl der je Populationslösung verwendeten SPSSA-Verbesserungsschritte von $\bar{v} = 10$ festgelegt, welche ebenfalls empirisch ermittelt ist.

Mögliche systematische Ansätze zur empirischen Bestimmung optimaler Parameterwerte zeigen [Coy et al. 2001] und [Adenso-Díaz und Laguna 2006]. Erstere Arbeit fokussiert sich dazu auf eine vom Anwender definierte Menge an strukturell prägnanten Probleminstanzen, konstruiert auf Basis jeder einzelnen Instanz ein einfach zu optimierendes Ersatzmodell, und wählt schließlich die Durchschnittswerte der so ermittelten optimalen Parameterwerte. Letztere Arbeit hingegen berücksichtigt die gesamte Menge der zu lösenden Probleme und vermeidet so eine Überanpassung an einzelne Probleminstanzen. Hierbei wird ein lokales Suchverfahren dazu verwendet, die erlaubte Bandbreite der Parameterwerte iterativ zu reduzieren. Bei der Gegenüberstellung dieser beiden Ansätze zeigt sich das Spannungsfeld, in dem sich eine Optimierung von Parametern bewegt: Soll der Algorithmus einzelne definierte Probleminstanzen besonders gut lösen oder als universelles Lösungswerkzeug auf allen im jeweiligen Kontext möglichen Problemen gute Ergebnisse erzielen? Als Resultat ihrer systematischen Parameteroptimierung finden [Adenso-Díaz und Laguna 2006] entsprechend auch lediglich heraus, dass die damit gefundenen Problemlösungen zwar häufig nicht besser sind als mit einer manuellen Optimierung (vergleichbare Effektivität), zumindest aber die Schnelligkeit und Robustheit der Verfahren häufig gesteigert werden kann (bessere Effizienz).

Bei der Implementierung der vorgestellten Verfahren wird auf eine solche systematische Parameteroptimierung verzichtet. Stattdessen sei auf naheliegende bzw. für den jeweiligen Algorithmus übliche Parameterwerte aufgebaut. In Fällen, in denen eine problemspezifische empirische Ermittlung von Parameterwerten notwendig ist, sind diese durch ein einfaches, manuelles Parametertuning mit begrenztem Aufwand ermittelt. Sowohl NELS, SPSSA als auch der Hybridalgorithmus zeigen hierbei eine geringe Robustheit gegenüber Parameterveränderungen, beispielsweise verschlechtert sich der SPSSA bei einer zu groß gewählten Schrittweite schnell auf ein Niveau unterhalb des GRS, und der NELS verliert bei einem zu klein gewählten Nachbarschaftsradius jegliche Fähigkeit zur Aufrechterhaltung einer gewünschten Diversität der Population im Lösungsraum. Eine Anpassung der Parameter dieser Algorithmen an die grundsätzliche Dimensionalität der Problemstellung ist also essenziell notwendig, was auch [Rajagopalan et al. 2007] in einer vergleichbaren Studie für die Implementierung solcher Heuristiken betonen.

Ziel des Vergleichs der Verfahren ist es entsprechend auch nicht, in einem Wettbewerb (Benchmarking) das absolut betrachtete beste Verfahren nach einem bestimmten Zielkriterium für ein konkretes Problem zu finden, sondern die generelle Eignung für die Klasse der betrachteten Problemstellungen in einem kontrollierten Experiment zu untersuchen (vgl. [Hooker 1995]). Der Vergleich mit einer kommerziellen Optimierungslösung wie OptQuest ist deshalb auch nur von beschränkter Aussagekraft, da OptQuest zwar kein problemspezifisches Tuning seiner verwendeten Optimierungsalgorithmen beinhalten kann, wohl aber für eine breite Masse möglicher Problemstellungen schon a priori bestmöglich gestaltet wurde.

Der strukturelle Ablauf aller betrachteten Optimierungsalgorithmen entspricht einer sequenziellen Optimierung (vgl. Kap. 5.1.2), analog zum Framework für Metaheuristiken von [Olafsson 2006]. Insbesondere wird hierbei das Budget der zur Optimierung zur Verfügung stehenden Simulationsläufe vorgegeben und eine bis dato beste evaluierte Lösung wird immer mitgeführt. Letzterer Punkt stellt zwar eine Einschränkung hinsichtlich einer prinzipiell erzielbaren besseren Effizienz dar, ermöglicht aber andererseits die Vergleichbarkeit der Verfahren untereinander sowie mit dem als Benchmark verwendeten und bereits in AnyLogic implementierten OptQuest, das ebenfalls wie in Kapitel 6.2.2 skizziert dem Paradigma der sequenziellen Optimierung folgt.

Zwar wird für die Optimierung ein von der Simulation unabhängiger Zufallszahlen-generator verwendet, ein Einsatz von Common random numbers (vgl. Kap. 7.1) beim Ablauf verschiedener Optimierungsalgorithmen ist hier jedoch nicht zweckdienlich. Grund hierfür ist, dass die Ziehung von Zufallszahlen strukturell bedingt nicht über die verschiedenen Verfahren hinweg oder auch nur über verschiedene stochastische Abläufe des identischen Verfahrens zu identischen Ablaufzeitpunkten synchronisiert werden kann.

Zur Durchführung der Algorithmenvergleiche wurden die in Kapitel 6.2 vorgestellten Verfahren in der Simulations- und Optimierungsumgebung AnyLogic (vgl. Kap. 4.6) als „Parameter Variation Experiment“ in Java implementiert. Als Hardware kam wiederum das auf Seite 91 beschriebene System zum Einsatz, ein Optimierungslauf mit 50.000 Simulationsauswertungen (ohne deren Grafikausgabe) benötigt hierauf je nach Algorithmus eine Laufzeit von knapp einer Stunde bei einem Load von ca. 80 % auf beiden Prozessorkernen.

7.2. Typische Optimierungsverläufe

Abbildung 44 zeigt anschaulich die typischen Verläufe einer Optimierung mit den jeweiligen Verfahren, wobei sich die Darstellungen zur besseren Identifikation relevanter Aspekte auf einige anfängliche Iterationen beschränken. Da sich die Algorithmen strukturell stark unterscheiden, ist auch jeweils die Einheit der Iteration unterschiedlich definiert, die Abschnitte auf der X-Achse sind also nicht zwischen den Algorithmen proportional vergleichbar.

Im Verlauf der Zufallssuche mit dem GRS fällt auf, dass der Algorithmus überwiegend schlechte Lösungen aus der unteren Hälfte der vertikalen Skala betrachtet, während gute Lösungen entsprechend ihrer bereits gezeigten statistischen Verteilung nur selten erreicht werden.

Beim SPSA bewegt sich die Verlaufslösung entlang der zusätzlich eingezeichneten Linie ausgehend von einer zufällig gewählten, relativ schlechten Lösung mit nur geringen Verbesserungen durch den Lösungsraum, bis schließlich in diesem Beispiel nach ca. 60 Iterationen eine Schwelle hin zu einem vielversprechenden Bereich des Lösungsraumes erreicht ist. Dort werden abermals sukzessive graduelle Verbesserungen erzielt, bis der Algorithmus ca. bei Iteration 340 schließlich keine Gradienten zur Verbesserung mehr findet, und durch eine Ausbruchregel in neue Bereiche des Lösungsraumes gelenkt wird.




Abbildung 44: Typische Optimierungsverläufe der einzelnen Verfahren

Quelle: eigene Berechnung und Darstellung

Anmerkung: Achsen haben technisch bedingt eine leicht voneinander abweichende Skalierung

Der NELS nimmt einen dem GRS ähnlichen Verlauf, jedoch ist die Qualität der untersuchten Lösungen im Schnitt deutlich höher, da die Lösungen nicht zufällig, sondern durch die Operatoren des evolutionären Algorithmus erzeugt werden. Entsprechend werden auch deutlich bessere Lösungen gefunden. Die zusätzlich eingezeichnete Linie zeigt, wie sich die durchschnittliche Qualität der zugrunde liegenden Population kontinuierlich verbessert, allerdings mit stark abnehmendem Momentum.

Der Hybridalgorithmus wiederum entspricht dem Optimierungsverlauf des NELS, wobei insbesondere zu Beginn der Optimierung die eingestreuten SPSSA-Schritte zur lokalen Verbesserung der Lösungen in der Population ihre Wirkung zeigen und die beste gefundene Lösung vergleichsweise schnell kontinuierlich verbessern können.

7.3. Vergleichskriterien und -maßstäbe

Zum Vergleich der Leistungsfähigkeit verschiedener Optimierungsalgorithmen findet man in der Literatur eine Vielzahl möglicher Ansätze und Kriterien (siehe z. B. [Bartz-Beielstein 2006], Kap. 7.2), welche sich je nach Problemstellung unterschiedlich geeignet zeigen.

Da die in der vorliegenden Arbeit betrachtete SBO auf einer komplexen stochastischen Simulation aufbaut, für die es kein störungsfreies deterministisches Ausgangsmodell gibt, scheiden folglich alle Kriterien der Bewertung aus, die einen bekannten Optimalwert der zu findenden besten Lösung voraussetzen, z. B. zur Messung der noch vorhandenen Lücke hin zu diesem Optimalwert. Grenzwertig erscheinen Kriterien, die von der Laufzeit des Algorithmus abgeleitet sind, da diese je nach Implementierungsumfeld (z. B. der verwendeten Programmiersprache oder der Wahl einer geschickten Programmierung) stark schwanken kann und somit potenziell weniger vom Algorithmus selbst abhängt (vgl. [Hooker 1995]). Ebenso wenig geeignet sind Kriterien auf Basis der Anzahl Iterationen, da dieses Maß wie bereits erwähnt je Algorithmus sehr unterschiedlich interpretiert wird. Augenscheinlich nicht geeignet sind außerdem Kriterien, die auf der Erfolgsquote des Algorithmus beruhen, eine gültige Lösung zu finden, da diese Voraussetzung in der hier betrachteten Problemstellung ohne weitere Nebenbedingungen durch jede Lösung des Definitionsbereichs Θ erfüllt ist.

Hingegen sind Kriterien als Maß für die Leistungsfähigkeit eines Algorithmus im betrachteten Kontext geeignet, die auf den eingesetzten Ressourcen (Anzahl Simulationsläufe bzw. Zielfunktionsauswertungen) und Güte der besten gefundenen Lösung (Zielfunktionswert) aufbauen (vgl. auch [Spall 2003], S. 13, und [Xu et al. 2010], Abs. 5). Diese beiden inhärent gegensätzlichen Maße stellen prägnant das grundsätzliche Spannungsfeld der simulationsbasierten Optimierung dar. Bei der Anwendung dieser Vergleichsmaße liegt die hier zutreffende Annahme zugrunde, dass der Overhead für die Abarbeitung des Optimierungsalgorithmus gegenüber dem Aufwand für die Simulation vernachlässigbar ist; die Anzahl der Simulationsläufe ist also ein proportionales Maß des eingesetzten Aufwands.

Es ergeben sich zwei grundsätzlich mögliche Zielkriterien für den Vergleich der betrachteten SBO-Algorithmen: 1) die Maximierung der Güte der besten gefundenen Lösung für einen gegebenen Simulationsaufwand oder 2) die Minimierung des Simulationsaufwands zur Erreichung einer gegebenen Schwelle des Zielfunktionswerts. Wie in Kapitel 7.1 ausgeführt, ist

das Budget an Simulationsläufen \bar{S} vorab festgelegt. Die Güte der hiermit gefundenen Lösung wird entsprechend als das zu maximierende Zielkriterium im Algorithmenvergleich verwendet.

Um stochastische Einflüsse bei der Bewertung der Algorithmen soweit möglich zu minimieren, werden die Optimierungsverfahren mehrfach mit jeweils einer zufälligen Belegung ihrer Zufallsvariablen durchgeführt. Als Maßstab für den Vergleich der Algorithmen kann man zwischen drei einfachen Kennzahlen unterscheiden: bester bzw. schlechtester Wert innerhalb der Menge der mit einem Algorithmus durchgeführten Optimierungsläufe („Peak performance“) oder deren Stichproben-Mittelwert („Average performance“). Zusätzlich lässt sich das Verhältnis einer Verbesserung der Güte der besten gefundenen Lösung zum dafür eingesetzten Simulationsaufwand als Schnelligkeit des Optimierungsverlaufs interpretieren und für ein festgelegtes Intervall an Simulationsläufen analysieren. Als nachrangiges Unterscheidungsmerkmal kann zudem die Varianz der Lösungsgüte innerhalb der Stichprobe der Optimierungsläufe dienen. Einen alternativ möglichen Ansatz stellen die bereits auf Seite 106 diskutierten nichtparametrischen statistischen Testverfahren dar (siehe auch [Büning und Trenkler 1994]), die nicht nur einen repräsentativen Wert, sondern die gesamte Stichprobe für den Vergleich der Algorithmen berücksichtigen.

Um die Gültigkeit der gewonnenen Erkenntnisse für eine praktische Anwendung zu gewährleisten, steht im Folgenden als Maßstab der Stichproben-Mittelwert der verschiedenen unabhängigen stochastischen Optimierungsläufe im Fokus. Somit müssen gute Algorithmen eine gute durchschnittliche Leistung zeigen, eine Leistungsspitze auf einzelnen Szenarien ist nicht entscheidend. Zusätzlich wird die Varianz der Werte innerhalb der Stichprobe in die Analyse mit einbezogen. Abgerundet wird der Vergleich der Algorithmen schließlich durch die Anwendung des Wilcoxon-Rangsummentests als geeignetem statistischen Testverfahren.

7.4. Vergleichsdurchführung und -ergebnisse

Das Experiment für den Vergleich der Algorithmen gliedert sich in fünf Testfälle, die jeweils durch einen Basiswert κ für die Saat des Zufallsgenerators der Simulation definiert sind. Für die m -te Replikation ($S^{\min} \leq m \leq S^{\max}$) ergibt sich entsprechend ein Wert der Saat von $\kappa + m$. Für jeden Testfall werden 50 unabhängige stochastische Optimierungsläufe mit jedem der betrachteten Verfahren durchgeführt. Auf dieser Stichprobe von insgesamt 250 Optimierungsläufen pro Algorithmus werden die erwähnten Vergleichsmaßstäbe berechnet. Diese Anzahl der aufgewendeten Optimierungsläufe entspricht ähnlichen Vergleichen von Algorithmen in der Literatur oder übertrifft diese, beispielsweise verwenden [Andradottir und Prudius 2009] 50–100 unabhängige Optimierungsläufe, [Spall 2003] (S. 251) sowie [Beyer 2000] verwenden 50 und [Maryak und Chin 2004] verwenden zehn Optimierungsläufe zum Vergleich eines evolutionären Algorithmus mit einem SPSA.

OptQuest stellt hierbei allerdings einen Sonderfall dar, da dieses Verfahren scheinbar keine stochastischen Komponenten enthält, sondern rein deterministisch abläuft. Eine mehrfache Optimierung kommt also reproduzierbar zum identischen Ergebnis, weshalb dieses Ver-

fahren auf einen einzigen Optimierungslauf pro Testfall (also insgesamt fünf) beschränkt und dessen Ergebnis dann ggf. fünfzigfach verwendet wurde.

Die Fortschrittsdiagramme in Abbildung 45 bis Abbildung 49 basieren auf der gemeinsamen Grundgesamtheit über alle Testfälle, wobei jeweils die bis dato beste gefundene Lösung mit deren evaluiertem Zielfunktionswert betrachtet wird. Diese besten Zielfunktionswerte sind in Relation zu der bis dahin aufgewendeten Anzahl an Simulationsläufen dargestellt. Die dargestellten Rechtecke sind begrenzt durch das obere und untere Quartil und umschließen so mittig den Median der Stichprobe. Die senkrechten Striche ober- und unterhalb der Rechtecke reichen vom Maximal- bis zum Minimalwert der Stichprobe. Die Höhe der Rechtecke und Striche ist also ein visuelles greifbares Maß für die Bandbreite der möglichen Optimierungsverläufe. Die gekrümmte Linie schließlich repräsentiert den Verlauf des Stichproben-Mittelwerts.

Der Algorithmus Global Random Search (GRS, siehe Abbildung 45) zeigt erwartungsgemäß für eine Zufallssuche eine kontinuierliche Verbesserung der gefundenen Werte und ebenso eine kontinuierliche Verringerung der Varianz über den Optimierungsverlauf hinweg.




Abbildung 45: Optimierungsverlauf des Algorithmus „Global Random Search“

Quelle: eigene Berechnung und Darstellung

Der Optimierungsverlauf von OptQuest (siehe Abbildung 46) zeigt, dass der Algorithmus sehr zügig und robust in den Bereich seines Optimums vordringt, darüber hinausgehende Simulationsläufe aber kaum noch für eine weitere Verbesserung nutzen kann. Im Durchschnitt kann sich der Algorithmus kaum gegenüber der zufälligen Suche des Global Random Search abgrenzen.




Abbildung 46: Optimierungsverlauf des Algorithmus „OptQuest“

Quelle: eigene Berechnung und Darstellung

Der Algorithmus SPSA (siehe Abbildung 47) bietet in der Spitze eine überzeugende Lösungsqualität. Auffällig ist jedoch die große Lücke zwischen dem Median (Mitte der Rechtecke) und dem Mittelwert (gekrümmte Linie) der Stichprobe. Diese Lücke resultiert aus der hohen Varianz in der Güte der besten gefundenen Lösung zwischen verschiedenen Optimierungsverläufen, die vereinzelt extreme Ausreißer nach unten aufweist. In diesen Fällen bleibt die Verlaufslösung des Algorithmus typisch für ein Punkt-zu-Punkt-Verfahren (vgl. Kap. 5.2.3.1) in einem Bereich stecken, der wenig Verbesserungspotenzial bietet, aber durch die Abfolge der SPSA-Schritte selbst unter Anwendung der implementierten Ausbruchregeln nur schwer oder gar nicht verlassen werden kann.




Abbildung 47: Optimierungsverlauf des Algorithmus „SPSA“

Quelle: eigene Berechnung und Darstellung

Eine in der Spitze vergleichbare Lösungsqualität zeigt der Algorithmus NELS (siehe Abbildung 48), jedoch gegenüber dem SPSA mit einer deutlich geringeren Varianz und speziell ohne signifikante Ausreißer nach unten.




Abbildung 48: Optimierungsverlauf des Algorithmus „NELS“

Quelle: eigene Berechnung und Darstellung

Die Kombination von NELS und SPSA im Hybridalgorithmus (siehe Abbildung 49) kann offenkundig von den Stärken der beiden Einzelverfahren profitieren und eine ausgewogene Mischung zwischen Diversifikation (über NELS) und Intensivierung (über SPSA und NELS) herstellen. Das Verfahren erzielt eine gegenüber dem SPSA noch leicht verbesserte maximale Lösungsqualität und kann insbesondere die Ausreißer nach unten wirksam begrenzen, was gegenüber dem NELS die Varianz sogar noch verringert. Außerdem ist die hohe Lösungsqualität bereits zu Anfang des Optimierungsverlaufs augenscheinlich.




Abbildung 49: Optimierungsverlauf des Algorithmus „Hybrid NELS-SPSA“

Quelle: eigene Berechnung und Darstellung

Bei der Gegenüberstellung der untersuchten Optimierungsverfahren (siehe Abbildung 50) kann man grundsätzlich feststellen, dass sich sowohl der NELS, der SPSA als auch der Hybridalgorithmus im Durchschnitt der Stichprobe wie auch in den Minimal- und Maximalwerten klar von der zufälligen Suche des Global Random Search absetzen, also eine prinzipielle Eignung für die hier betrachtete Parameteroptimierung einer ABS zeigen.

Auffällig ist, dass sich der Global Random Search trotz seiner Einfachheit gegenüber den State-of-the-art-Verfahren der SBO vergleichsweise gut schlägt, was generell bei hochdimensionalen Problemstellungen nicht der Fall sein sollte (vgl. z. B. [Spall et al. 2006], Abschnitt 3.6). Der Grund hierfür ist in der in Kapitel 6.1 beschriebenen typischen Struktur der SBO einer ABS zu finden, die der Effizienz eines strukturierten Optimierungsverfahrens offensichtlich enge Grenzen setzt. Dies begründet wohl auch, warum das in vielen anderen Studien und Praxisanwendungen erfolgreich eingesetzte OptQuest über die fünf Testfälle hinweg durchgängig keine überzeugende Lösungsqualität bieten kann.

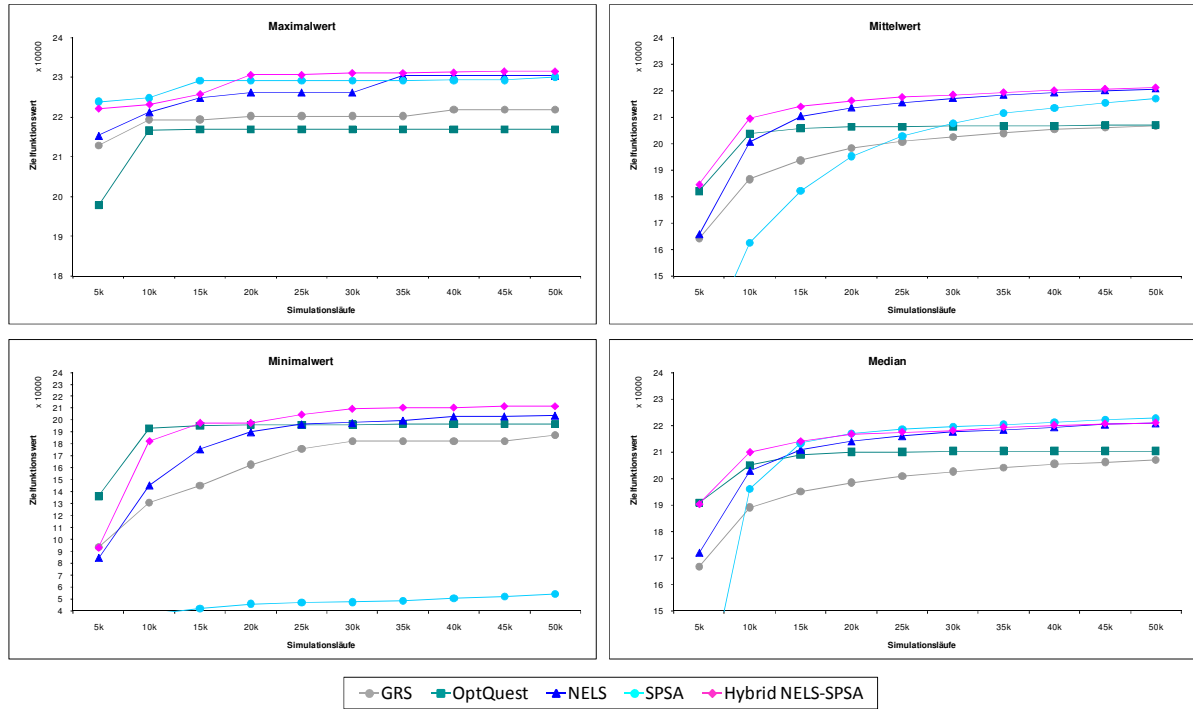


Abbildung 50: Vergleich der Optimierungsverläufe (Unter-/Obergrenzen, Mittelwerte, Mediane)

Quelle: eigene Berechnung und Darstellung

Mit linearen Rangstatistiken lassen sich die Ergebnisse der Optimierungsläufe ebenfalls jeweils in Relation zueinander beurteilen; diese nichtparametrische statistische Testmethodik setzt keine Verteilungsannahme bezüglich der Optimierungsergebnisse voraus. Hierzu seien die Rangsummen einer gemeinsamen geordneten Stichprobe der Optimierungsergebnisse sowie der darauf aufbauende Wilcoxon-Rangsummentest zur Abgrenzung der Ergebnisse voneinander verwendet (als Referenz siehe [Bünig und Trenkler 1994], Kap. 5.3 f.).

Es seien $X_{1...50}^{GRS}$, $X_{1...50}^{OptQ}$, $X_{1...50}^{SPSA}$, $X_{1...50}^{NELS}$ und $X_{1...50}^{Hybrid}$ die unabhängigen Stichprobenvariablen der 50 Optimierungsläufe je Algorithmus. In einer kombinierten Stichprobe werden die Ausprägungen der Variablen absteigend geordnet und dadurch jeder Stichprobenvariablen eine Rangziffer $R(X_{[*]}^{[*]})$ zugeordnet, beginnend mit $R(X_{[*]}^{[*]}) = 1$ für die Stichprobenvariable mit der besten Ausprägung.

Betrachtet man die Summen der Rangziffern $W^{[*]} = \sum_{i=1...50} R(X_i^{[*]})$ der durchgeführten Optimierungsläufe in der kombinierten Stichprobe (d. h. mit insg. 1.250 einzelnen Stich-

probenvariablen) bezogen auf die einzelnen Algorithmen, so ergibt sich eine recht klare Ordnung der Algorithmen hinsichtlich ihrer Lösungsgüte: $W^{SPSA} < W^{Hybrid} < W^{NELS} < W^{OptQ} < W^{GRS}$ (siehe Abbildung 51, linke Spalte), wobei kleine Rangziffern für eine bessere Lösungsgüte stehen.

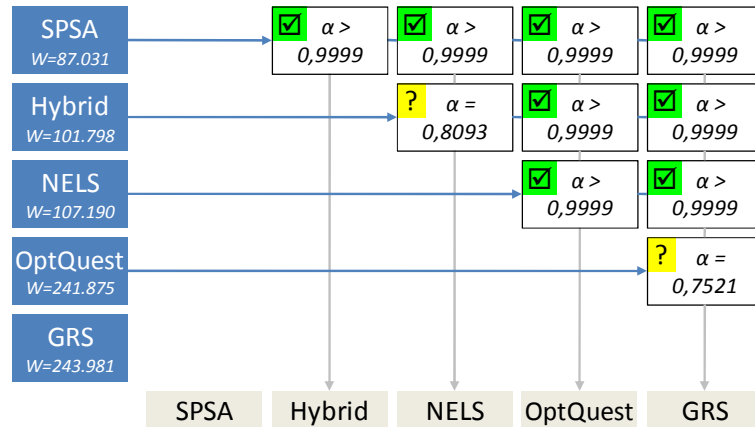


Abbildung 51: Stochastische Dominanz mit Signifikanzniveau α

Quelle: eigene Berechnung und Darstellung

Ein Wilcoxon-Rangsummentest³³ auf einer kombinierten Stichprobe von jeweils zwei der Algorithmen ergibt, dass diese Ordnung bis auf Einzelfälle bei einem Niveau von $\alpha > 0,9999$ stochastisch signifikant ist (vgl. Abbildung 51). Lediglich gegenüber dem NELS zeigt sich der Hybridalgorithmus nicht signifikant überlegen, Gleiches gilt für OptQuest im Vergleich zum Global Random Search.

Speziell im Kontext der Optimierung einer stochastischen Simulation besteht ein strukturell ausgeprägtes Problem darin, dass unter mehreren nahe beieinanderliegenden (angenommen ähnlich guten) Lösungen immer diejenige als die beste Lösung identifiziert wird, die bei der Evaluation zufällig am meisten überschätzt wird. Dieser Effekt ist ein bekanntes Phänomen (siehe auch [Xu et al. 2010]) und tritt insbesondere bei Algorithmen auf, die verstärkte Mechanismen zur Lokalsuche einsetzen, also häufig verschiedene nahe beieinanderliegende Lösungen evaluieren. Diese Überschätzung schmälert generell die Leistungsfähigkeit eines Algorithmus, da als Referenz eigentlich nicht der in der Optimierung berechnete Zielfunktionswert verwendet werden kann. Vielmehr muss der tatsächliche, überschätzungsfreie Zielfunktionswert durch eine intensivere Evaluation nachträglich neu ermittelt werden.

Bezogen auf die hier verglichenen Algorithmen tritt dieser Effekt unterschiedlich stark hervor. Zur Analyse wurden pro Algorithmus die besten zehn gefundenen Lösungen (bzw. die insg. fünf gefundenen Lösungen bei OptQuest) einer eingehenden Evaluation mit 10.000 Replikationen unterzogen, was die Unsicherheit in der Bewertung der jeweiligen Lösung von durchschnittlich ca. 1.200 (entspricht $\sim 0,5\%$) auf ca. 270 ($\sim 0,1\%$) reduziert hat. Die

³³ Einseitiger Wilcoxon-Rangsummentest mit approximierter Verteilung der $X_i^{[*]}$ wie in [Bünig und Trenkler 1994] (S. 134) dargestellt.

Differenz zwischen dem ursprünglich mit $S^{max} = 500$ Replikationen evaluierten Zielfunktionswert und dem nun mit 10.000 Replikationen intensiver evaluierten Wert stellt den Fehler aus einer Überschätzung dar, prozentual bezogen auf den weniger intensiv evaluierten Wert (siehe Tabelle 9). Ein Fehler von 1 % entspricht hierbei je nach Lösung einer Differenz von ca. 2.300 im Zielfunktionswert.

Algorithmus	GRS	OptQuest	NELS	SPSA	Hybrid
Ø Fehler	-0,1 %	-0,4 %	-0,2 %	-0,2 %	-0,1 %

Tabelle 9: Überschätzung im Rahmen des evaluierten Zielfunktionswerts

Quelle: eigene Analyse

Beim GRS ist die Überschätzung kaum ausgeprägt, da der Algorithmus keine Intensivierung durchführt, sondern nur eine globale Suche vollzieht. Die trotzdem vorhandene schwache Überschätzung kann man dadurch begründen, dass es auch hier vereinzelt zu einem Vergleich zweier ähnlich guter (nicht notwendigerweise beieinanderliegender) Lösungen kommt, bei dem die am meisten überschätzte Lösung als beste Lösung identifiziert wird. OptQuest hingegen zeigt einen vergleichsweise hohen Grad der Überschätzung, was auf eine ausgeprägte Lokalsuche schließen lässt. Die Algorithmen NELS und SPSA sind gegenüber dem GRS kaum anfälliger für Überschätzung, der Hybridalgorithmus liegt diesbezüglich sogar mit dem GRS gleichauf, vermutlich aufgrund seiner erweiterten Fähigkeiten zur Diversifikation. Bei den drei Algorithmen NELS, SPSA und Hybrid muss die Überschätzung bei der Beurteilung entsprechend nicht besonders einkalkuliert werden, da diese keinen übermäßigen Einfluss auf den zurückgelieferten Ergebniswert hat.

Bei einer Abwägung aller betrachteten Vergleichsmaße bietet sich aus Sicht des Autors insbesondere der Hybridalgorithmus für den praktischen Einsatz an. Dieses Verfahren wird zwar im Wilcoxon-Test klar vom SPSA geschlagen, zeigt aber eine ebenso deutlich geringere Variabilität. Insbesondere ist die daraus resultierende geringe Bandbreite bei unterschiedlichen stochastischen Durchläufen in der praktischen Anwendung relevant, da hier oftmals nur mit einzelnen Optimierungsläufen gearbeitet werden kann. Aus diesen Gründen wird der Hybridalgorithmus für die experimentellen Studien im folgenden Kapitel 8 eingesetzt.

7.5. Ausblick auf weitere Effizienzsteigerung

Grundlage der Algorithmenvergleiche in diesem Kapitel war mit der sequenziellen Optimierung (vgl. Kapitel 5.1.2) ein Framework, das ein recht restriktives Korsett für die eingesetzten Verfahren darstellt. Erst durch diese Einschränkungen wurde ein fairer Vergleich der Algorithmen ermöglicht, andererseits ist hierdurch aber auch die idealtypische Leistungsfähigkeit der einzelnen Verfahren begrenzt. Deshalb seien an dieser Stelle noch einige mögliche Erweiterungen aufgezeigt, die dazu dienen können, die Algorithmen in einem weniger restriktiven Kontext noch leistungsfähiger zu machen.

Bei der sequenziellen Optimierung ist es eine zentrale Voraussetzung, dass der Optimierungsablauf jederzeit abgebrochen werden kann und entsprechend zu jedem Zeitpunkt eine bis dahin beste gefundene Lösung evaluiert mitgeführt werden muss. Geht man jedoch davon aus, dass das Simulationsbudget ohne Abbruch komplett ausgeschöpft werden kann, lässt sich der Optimierungsprozess holistisch planen. So lassen sich z. B. Abwägungen zwischen der Exploration einerseits und der Evaluation andererseits explizit treffen (was z. B. von [Lin und Lee 2006] gezeigt wird) oder während des Optimierungsverlaufs kann eine dynamische Anpassung vorausschauend erfolgen. Dadurch ergeben sich auch neue Möglichkeiten, den Simulationsaufwand je Lösung nicht sofort komplett aufzubrauchen und so mögliche Effizienzgewinne zu erschließen. Im Rahmen eines mehrstufigen Prozesses könnten Lösungen zuerst einem Screening mit nur begrenztem Simulationsaufwand unterzogen werden und nur wenn sie diese Hürde überwinden, werden einzelne Lösungen bei einer später folgenden Evaluation näher betrachtet. Da zu dem späteren Zeitpunkt präzisere Informationen hinsichtlich einer unteren Schranke der erzielbaren Lösungsgüte zur Verfügung stehen, kann das abermalige Screening einen deutlich schärferen Schnitt vollziehen und mit insgesamt weniger Simulationsauswertungen mehr Lösungen ausschließen. Lediglich diejenigen Lösungen, welche das (evtl. auch mehrstufige) Screening überstehen, werden bis zum maximalen Simulationsaufwand S^{max} repliziert und so final evaluiert. Beschränkt man sich nicht nur auf einen einzelnen Lauf der sequenziellen Optimierung, so kann eine solche untere Schranke der Lösungsgüte auch schon aus vorangegangenen Optimierungsläufen bekannt sein. Alternativ kann sich eine solche Schranke auch direkt aus der Problemstellung erschließen, dann kann diese auch ohne Widerspruch zum Framework der sequenziellen Optimierung von Beginn des Optimierungslaufs an genutzt werden. Ebenso bieten sich potenziell mögliche Effizienzgewinne, wenn man nicht nur die beste Lösung speichert und mitführt, sondern auch alle anderen Lösungen zwischenspeichert. So lässt sich eine doppelte Überprüfung einzelner Lösungen vermeiden. Außerdem können die so erhalten gebliebenen Informationen genutzt werden, um Bereiche im Lösungsraum als vielversprechend zu identifizieren oder zu verwerfen (vgl. auch [Hong und Nelson 2006]).

Für den Ablauf des NELS könnte man die Anzahl der zur Evaluation einer Lösung verwendeten Replikationen über den Optimierungsverlauf hinweg kontinuierlich steigen lassen, um erst am Ende eine vollständige Evaluation aller Lösungen der letzten Generation durchzuführen, aus denen dann die beste Lösung das Ergebnis der Optimierung darstellt. Überlegungen von [Beyer 2000] folgend könnte man auch ganz auf die Evaluation im Verlauf des NELS verzichten, da evolutionäre Algorithmen strukturell bedingt eine hohe Robustheit gegenüber stochastischen Zielfunktionsauswertungen aufweisen. Die stark ausgeprägte Unsicherheit in der Lösungsbewertung bei Problemstellungen der Optimierung einer ABS (vgl. Kapitel 6.1) übersteigt jedoch eventuell das selbst für einen robusten Algorithmus vertretbare Maß. Zudem verhindert die stark zerklüftete Oberfläche eine klassische Konvergenz zum globalen Optimum. Angebracht wäre bei einem solchen Ansatz dann jedenfalls der Verzicht auf die Übernahme elitärer Lösungen in die Folgegenerationen, da diese mangels eingehender Evaluation stark überschätzt sein könnten und damit den Optimierungsverlauf unnötig hemmen, wie [Beyer 2000] für ein spezielles Problem zeigt.

Auch beim SPSA ist eventuell gar keine Evaluation im Optimierungsverlauf notwendig, vielmehr könnte man sich auf die Konvergenzeigenschaften des Algorithmus verlassen und erst ganz zum Schluss eine Evaluation der letzten untersuchten Lösung(en) durchführen.

Ein für die praktische Anwendung vielversprechender Algorithmus würde diese genannten Aspekte idealerweise kombinieren. [Boesel, Nelson und Kim 2003] skizzieren z. B., wie ein solches wegweisendes Verfahren aussehen könnte. Übertragen auf die in der vorliegenden Arbeit betrachteten Algorithmen könnte (1) der hybride Algorithmus aus NELS und SPSA dazu verwendet werden, den Lösungsraum zu durchsuchen. In dieser Phase wird lediglich eine begrenzte Anzahl an Replikationen benötigt, um die Lösungen für den folgenden Schritt zu ordnen. Nach Abschluss des Suchalgorithmus erfolgt (2) ein Screening, das klar schlechte Lösungen ohne zusätzliche Replikationen vorab ausschließt. Für die verbliebenen Lösungen werden (3) zusätzliche Replikationen durchgeführt, bis eine klare Identifikation der besten Lösung mit der gewünschten Konfidenz erreicht ist oder bis eine hinreichende Abtrennung der besten Lösung möglich ist (beispielsweise nach einem Kriterium analog zu [Branke und Schmidt 2004]). Festzulegen bliebe hierbei, wie ein vorgegebenes Simulationsbudget geschickt auf die Phasen (1) und (3) aufzuteilen wäre, gegebenenfalls unter Relaxation der Forderung nach einer statistischen Konfidenz bei der Identifikation der besten Lösung, falls das Simulationsbudget frühzeitig aufgebraucht ist.

Dessen ungeachtet lassen sich die vorgestellten Algorithmen aber auch innerhalb des Frameworks der sequenziellen Optimierung weiter verbessern. Für den SPSA müsste noch effektiver verhindert werden, dass der Algorithmus in relativ schlechten Bereichen des Lösungsraumes stecken bleibt. Das Problem könnte adressiert werden, indem unter bestimmten Umständen ein kompletter Neustart auf einer anderen, zufällig gewählten Lösung vollzogen wird. Dies entspricht der Durchführung mehrerer Optimierungsläufe jeweils mit reduziertem Simulationsbudget, sodass in Summe das gleiche Gesamtbudget wie beim ursprünglichen SPSA genutzt wird. Dadurch könnten die Fälle, in denen der SPSA in relativ schlechten Bereichen stecken bleibt, reduziert werden. Initiale Tests auf dem in diesem Kapitel betrachteten Optimierungsproblem liefern zumindest Indizien für die potenzielle Überlegenheit dieser Erweiterung gegenüber dem implementierten SPSA-Verfahren, eine eindeutige Dominanz ist jedoch nicht festzustellen.

Der NELS würde eventuell davon profitieren, nicht mit einer komplett zufällig gewählten Population zu starten, sondern diese initialen Lösungen systematischer zu wählen, z. B. aus der Menge der Eckpunkte des Definitionsbereichs (wie auch im Scatter Search, vgl. Kap. 5.2.3.2). Dieses Vorgehen stellt zu Beginn eine hohe Diversität der Lösungen und eine umfängliche Abdeckung des gesamten Lösungsraumes sicher, bevor durch Rekombination und Mutation die dazwischenliegenden Bereiche im Optimierungsverlauf erschlossen werden. Für die in dieser Arbeit betrachtete Problemstellung zeigt diese Modifikation in Tests jedoch keine Verbesserung des Verfahrens, weswegen sie auch nicht eingesetzt wird.

Sowohl für den NELS als auch für den Hybridalgorithmus wäre es aus Sicht des Autors interessant zu untersuchen, wie sich die Struktur der Population im Verlauf der Optimierung entwickelt. Aufschlussreiche Untersuchungsgegenstände wären hierbei die

Zusammensetzung der Population, die Geschwindigkeit, mit der die Algorithmen in Richtung vielversprechender Bereiche des Lösungsraumes konvergieren (also implizit von Diversifikation auf Intensivierung umschalten) und die Bereiche selbst, zu denen die Algorithmen hin konvergieren (lokale bzw. globale Optima). Eine detaillierte Analyse könnte zeigen, ob der gewählte Nachbarschaftsradius generell geeignet ist zur Aufrechterhaltung einer zweckadäquaten Diversität der in der Population enthaltenen Lösungen oder ob eine zu starke oder zu wenig ausgeprägte Intensivierung hin zu guten Lösungen stattfindet.

8. Experimentelle Fallstudien

Mithilfe einer ABS lassen sich wie in Kapitel 3 ausführlich beschrieben mikroökonomisch fundierte reale Systeme in einem Simulationsmodell studieren. Geht der Zweck der Analyse aber über den reinen Ablauf der Simulation hinaus in Richtung der Optimierung einer ABS, betritt der Forscher weitgehendes Neuland. Aus Sicht des Operations Research wird ein Werkzeug wie die ABS aber erst genau dann interessant, wenn es die Möglichkeit bietet, durch Optimierung bestmögliche Entscheidungen in einem realen System zu identifizieren. Der Optimierung kommt also eine wichtige Bedeutung zu; mit ihrer Hilfe erschließen sich der ABS gänzlich neue Anwendungsfelder.

Im Verlauf dieses Kapitels werden verschiedene Fallstudien vorgestellt, welche die Möglichkeiten des Einsatzes der SBO im Rahmen einer ABS exemplarisch darstellen. Hierzu wird abermals auf das in Kapitel 4 vorgestellte Simulationsmodell des deutschen Mobilfunkmarktes zurückgegriffen. Aus der Sicht eines Mobilfunkanbieters wird sich dabei mit der Frage beschäftigt, wie der Anbieter durch eine Anpassung der Preiskomponenten seines Tarifportfolios seinen wirtschaftlichen Erfolg steigern kann (vgl. Kap. 8.1), beziehungsweise wie er diesen optimal gestaltet (vgl. Kap. 8.2.1). In einer Erweiterung der Fallstudie auf alle vier Anbieter wird darauf aufbauend untersucht, was in dem simulierten Markt geschieht, wenn alle Anbieter ihre Preise mit der gezeigten Methodik hintereinander oder parallel optimieren (vgl. Kap. 8.2.2 und 8.2.3). Die im Modell einbezogenen Vereinfachungen bedingen, dass das Ziel an dieser Stelle nicht der Entwurf eines praktisch einsetzbaren Decision-Support-Systems ist, sondern vielmehr die prototypische Demonstration der Anwendbarkeit der in den Kapiteln 6 und 7 vorgestellten Verfahren der SBO.

In den folgenden Fallstudien sei als Ziel der Preisoptimierung das Kriterium der Umsatzmaximierung gewählt. Der Umsatz bezieht sich in diesem Fall auf die Summe der periodischen Grund- und variablen Nutzungsgebühren, bezogen für alle Kunden auf deren festgelegte Nutzung und kumuliert über den gesamten betrachteten Zeitraum von 36 Simulationsperioden. Methodisch gesehen ist die Optimierung der Preise des Anbieters auf Basis der in Kapitel 4 gezeigten ABS eine Mischung aus simultaner nachfrage- und wettbewerbsorientierter Preisbestimmung, was auch der üblichen Praxis im Mobilfunkmarkt entspricht (vgl. z. B. [Samanta et al. 2009]). Der wettbewerbsorientierte Aspekt der Preisbestimmung ist hierbei lediglich indirekt, da die Preise der Konkurrenz nicht direkt bei der Preisentscheidung des Anbieters berücksichtigt werden, wohl aber das Verhalten der Kunden in der Simulation beeinflussen und somit für die Preisentscheidung des Anbieters einen mittelbaren Einfluss darstellen. Eine kostenorientierte Preisbestimmung bleibt aufgrund der in Kapitel 2.3 gezeigten Charakteristika des Mobilfunkmarktes außen vor.

Experimentelle Fallstudien auf Basis von Simulationen ziehen ihren Wert essenziell aus einer detaillierten und nachvollziehbaren Dokumentation, da erst hierdurch die notwendige wissenschaftliche Fundierung der im undokumentierten Fall oft recht willkürlichen Daten und Ergebnisse erzeugt wird. Eine in dieser Beziehung aus Sicht des Autors vorbildliche Fallstudie ist z. B. die bereits an verschiedenen Stellen zitierte Arbeit von [Rahmandad und

Sterman 2008]. Ein hervorragender Leitfaden zur Aufarbeitung, Darstellung und Dokumentation einer solchen Studie findet sich außerdem bei [Barr et al. 1995]. Durch die detaillierte Beschreibung des Simulationsmodells in Kapitel 4 und die ebenfalls umfassende Beschreibung und Diskussion des verwendeten Optimierungsverfahrens in Kapitel 6 ist in Bezug auf die vorliegende Arbeit hierfür der Grundstein gelegt. Entsprechend finden sich in diesem Kapitel nur noch dann beschreibende Angaben, wenn sich diese speziell auf die Fallstudie beziehen oder von den grundlegenden Modellierungen oder Verfahren abweichen.

8.1. Fallstudie zur Simulation

Als Ausgangsszenario dieser Fallstudie dient die in Kapitel 4.5 beschriebene Parametrisierung der Simulation des Mobilfunkmarktes. Gegenstand der Analyse sei der über die Perioden kumulierte Umsatz, den der Anbieter \mathbb{D} mit seinem Tarifportfolio auf dem Markt mit 1.000 modellierten Kunden generiert. Im Ausgangsszenario beträgt dieser Umsatz 102.921 € als Durchschnittswert 500 simulierter Replikationen. Hierbei haben zum Ende der 36 Simulationsperioden im Durchschnitt 0,3 % der Agenten einen Vertragstarif bei Anbieter \mathbb{D} , 3,2 % einen Zeittarif und 7,8 % einen Pauschaltarif.

Als beeinflussbare Größen hat der Anbieter die Preise seines Tarifportfolios, die in Tabelle 10 dargestellt sind. Aus Sicht dieses Anbieters lautet die konkrete Fragestellung, welche Auswirkungen mögliche Preisänderungen auf den Umsatz hätten. Hierzu soll die Sensitivität des Gesamtumsatzes bezogen auf die einzelnen Preiskomponenten betrachtet werden und die Elastizität, mit der sich Preisänderungen auf den Umsatz auswirken. Die Sensitivität ist hierbei ein Maß für die Effektivität einer Preismaßnahme, während die Elastizität der Preis-Umsatz-Funktion die Effizienz der Maßnahme beschreibt. [Doganoglu und Grzybowski 2007] schätzen derartige Elastizitäten auch für den realen deutschen Mobilfunkmarkt, jedoch sind die betrachteten Grundgesamtheiten zwischen deren Analyse und dem hier verwendeten Modell zu unterschiedlich, als dass man die resultierenden Werte vergleichen könnte.


Anbieter	Tariftyp	Minutenpreis	Grundgebühr	Inklusivminuten
\mathbb{D}	Vertrag	0,28 €	21 €	35
	Zeit	0,37 €	-	-
	Pauschal	-	22 €	∞

Tabelle 10: Beeinflussbare Größen der Fallstudie


Quelle: eigene Darstellung

Um die prozentuale Preis-Umsatz-Elastizität zu messen, wird vom Ausgangsszenario jede der einzelnen Preiskomponenten jeweils um plus beziehungsweise minus fünf Einheiten variiert. Auf der Basis dieser experimentell ermittelten Daten berechnet sich die jeweilige durchschnittliche Elastizität (wiederum bezogen auf 500 Replikationen je Szenario) über dieses gesamte Intervall (siehe Tabelle 11) anhand der Formel:


$$\text{Elastizität} = \frac{\Delta \text{Umsatz im Intervall}}{\text{Umsatz im Ausgangsszenario}} \bigg/ \frac{\Delta \text{Preis im Intervall}}{\text{Preis im Ausgangsszenario}}$$



ID Vertrag Minutenpreis (€)	0,23	0,24	0,25	0,26	0,27	0,28	0,29	0,30	0,31	0,32	0,33
Umsatz (k€)	100,9	101,3	102,0	101,9	103,1	102,9	103,9	103,5	104,1	104,5	105,7
Kunden Vertragstarif (#)	0,4 %	0,4 %	0,3 %	0,3 %	0,3 %	0,3 %	0,3 %	0,3 %	0,2 %	0,2 %	0,2 %
Kunden Zeittarif (#)	3,2 %	3,1 %	3,2 %	3,1 %	3,2 %	3,1 %	3,2 %	3,1 %	3,1 %	3,2 %	3,2 %
Kunden Pauschaltarif (#)	7,7 %	7,8 %	7,8 %	7,8 %	7,9 %	7,8 %	7,9 %	7,8 %	7,8 %	7,9 %	7,9 %



ID Vertrag Grundgebühr (€)	18,5	19	19,5	20	20,5	21	21,5	22	22,5	23	23,5
Umsatz (k€)	100,5	101,7	102,9	103,0	103,1	102,9	104,2	103,7	104,4	105,0	104,9
Kunden Vertragstarif (#)	0,4 %	0,4 %	0,4 %	0,3 %	0,3 %	0,3 %	0,3 %	0,3 %	0,2 %	0,2 %	0,2 %
Kunden Zeittarif (#)	3,1 %	3,2 %	3,2 %	3,2 %	3,2 %	3,1 %	3,2 %	3,2 %	3,2 %	3,2 %	3,2 %
Kunden Pauschaltarif (#)	7,7 %	7,8 %	7,9 %	7,8 %	7,9 %	7,8 %	7,9 %	7,9 %	7,8 %	7,9 %	7,9 %



ID Vertrag Inklusivmin. (#)	10	15	20	25	30	35	40	45	50	55	60
Umsatz (k€)	107,1	106,4	105,4	104,7	103,6	102,9	102,8	101,5	101,6	101,3	101,6
Kunden Vertragstarif (#)	0,1 %	0,2 %	0,2 %	0,2 %	0,3 %	0,3 %	0,3 %	0,4 %	0,5 %	0,6 %	0,7 %
Kunden Zeittarif (#)	3,2 %	3,2 %	3,3 %	3,2 %	3,2 %	3,1 %	3,1 %	3,1 %	3,1 %	3,2 %	3,1 %
Kunden Pauschaltarif (#)	7,9 %	7,9 %	7,9 %	7,9 %	7,8 %	7,8 %	7,9 %	7,7 %	7,8 %	7,8 %	7,7 %



Tabelle 11: Preis-Umsatz-Elastizitäten ausgehend vom Ausgangsszenario

Quelle: eigene Berechnung und Darstellung

Auffallend ist hierbei vor allem die vergleichsweise hohe (negative) Elastizität der Grundgebühr des Pauschaltarifs von -218 %, die nahelegt, dass eine Veränderung an dieser Stellschraube die mit Abstand größten praktischen Auswirkungen auf den Umsatz haben dürfte. Dieser Zusammenhang ist begründet in der Kundenstruktur des Anbieters D im Ausgangsszenario, dessen Kunden hauptsächlich Pauschaltarife abgeschlossen haben. Eine Preiserhöhung des Pauschaltarifs macht diesen offensichtlich für eine große Anzahl dieser Kunden unattraktiv, die Grundgebühr des Pauschaltarifs stellt also einen relevanten Hebel für den Anbieter dar.

Teilweise zeigen die Elastizitäten ihrer Ausprägung oder sogar ihrem Vorzeichen nach einen nicht sofort intuitiv nachvollziehbaren Wert. Neben dem einfachen Zusammenhang, dass eine Preiserhöhung bei gleichbleibender Kundenzahl zu einem steigenden Umsatz und vice versa führt (was man an den Preiskomponenten des Vertragstarifs ansatzweise sehen kann), umfasst dieser komplexe Markt jedoch offensichtlich noch weitere Mechaniken. So kann eine Preiserhöhung in einem Tarif auch dazu führen, dass dieser zwar unattraktiv wird, der nächstbeste Tarif aber weiterhin beim selben Anbieter ist. In diesem Fall kann der Gesamtumsatz des Anbieters sogar steigen. Liegt der nächstbeste Tarif jedoch bei einem konkurrierenden Anbieter, geht Umsatz für den Anbieter verloren. Eine Preissenkung kann

ebenfalls zu steigenden Umsätzen führen, wenn hierdurch neue Kunden gewonnen werden und deren zusätzliche Umsätze die durch die Preissenkung verlorenen Umsätze überkompensieren (was man bei dem Zeit- und Pauschaltarif sehen kann). Oft ergibt sich die Ausprägung der Elastizität auch nicht allein aus der neu entstandenen Wettbewerbspositionierung, sondern resultiert zum Teil aus Netzwerkeffekten, die eine nachgelagerte Verstärkung der Elastizität bewirken können. Dies geschieht insbesondere, wenn durch die Preismaßnahme neue Kunden zu einem Anbieter wechseln (direkter Umsatzeffekt), die dann in ihrer lokalen Nachbarschaft die Wettbewerbspositionierung des Anbieters zusätzlich verstärken und so potenziell zu weiteren Neukunden führen (nachgelagerter Umsatzeffekt). Besonders augenscheinlich wird diese Strahlungswirkung der Netzwerkeffekte bei der Preissenkung des Pauschaltarifs, die dazu führt, dass sich parallel zur wachsenden Anzahl der Kunden des Pauschaltarifs auch die Anzahl der Kunden des Zeittarifs verdoppelt, ohne dass sich die Bepreisung dieses Tarifs geändert hat.

In der Regel lassen sich diese Wirkungen bei der Gesamtbetrachtung des Marktes aber nicht isolieren. Der erzielte Umsatz ist also immer ein aggregiertes Resultat der parallel wirkenden Einflüsse. Da in der agentenbasierten Simulation jedoch auch die disaggregierten Daten der einzelnen Agenten vorliegen, könnte man recht einfach feingliedrigere Elastizitäten ermitteln, die sich z. B. auf die Umsätze der einzelnen Tarife beziehen oder auch die Anzahl der Kunden je Tarif einbeziehen, um so tiefere Einblicke zu gewinnen.

Die im Ausgangsszenario ermittelten Elastizitäten geben die Richtung an, in die der Anbieter sein Tarifportfolio zur Umsatzsteigerung entwickeln sollte. Ein solcher Schritt sei vollzogen, indem für jede der Preiskomponenten der Wert gewählt wird, der bei der Ermittlung der Elastizitäten (siehe Tabelle 11) den größten positiven Einfluss auf den Umsatz hatte. Dieser Schritt hat für den Anbieter spekulativen Charakter, da die Elastizitäten jeweils nur bezogen auf die Veränderung einer einzelnen Preiskomponente ermittelt wurden, eine parallele Veränderung mehrerer Preiskomponenten also auch durchaus unvorhergesehene negative Auswirkungen haben könnte. Es ergibt sich für den Anbieter \mathbb{D} folgende „verbesserte“ Preisstruktur für sein Tarifportfolio:

Anbieter	Tariftyp	Minutenpreis	Grundgebühr	Inklusivminuten
\mathbb{D}	Vertragstarif	0,33 €	23,5 €	10
	Zeittarif	0,32 €	-	-
	Pauschaltarif	-	19,5 €	∞

Tabelle 12: Verbessertes Szenario der Fallstudie

Quelle: eigene Darstellung

Eine Simulation mit der neuen Preisstruktur liefert wie erhofft eine signifikante Verbesserung des Umsatzes, die sogar noch über die besten bei der Variation des Ausgangsszenarios ermittelten Werte hinausgeht. Der Anbieter \mathbb{D} kann in diesem verbesserten Szenario seinen Umsatz auf 147.076 € steigern, wobei dann kaum noch Agenten einen Vertragstarif bei \mathbb{D} haben, jedoch 8,8 % einen Zeittarif und 16,7 % einen Pauschaltarif abgeschlossen haben. Die Veränderung der Preisstruktur hat also sowohl im Zeit- als auch im

Pauschaltarif zu einer Verdoppelung der Kundenzahl geführt. Trotz Preissenkungen in diesen beiden Tarifen konnte der Gesamtumsatz von Anbieter D signifikant gesteigert werden. Die neu ermittelten Elastizitäten der einzelnen Tarife deuten weiterhin auf mögliche Verbesserungspotenziale hin, für den Vertragstarif 15 %, 17 % und 28 % (Minutenpreis, Grundgebühr und Inklusivminuten), für den Zeittarif -26 % (Minutenpreis) und für den Pauschaltarif -160 % (Grundgebühr).

Die Methodik, anhand von Preiselastizitäten die Richtung erwarteter Verbesserungen zu identifizieren und dorthin einen Schritt zu vollziehen, lässt sich natürlich nun abermals anwenden, um so iterativ eine weitere Verbesserung des Umsatzes zu erzielen. Dieser manuelle Ansatz ist jedoch mühsam — für das Ausgangsszenario waren bereits $5 \cdot 10 \cdot 500 = 25.000$ Simulationsauswertungen (Preiskomponenten \cdot Variationseinheiten \cdot Replikationen) notwendig — und ungenau, da er methodisch einer sehr naiven Gradientenoptimierung entspricht. Effizientere Möglichkeiten zur simulationsbasierten Optimierung wurden bereits in Kapitel 6 vorgestellt, diese werden nun im folgenden Kapitel 8.2 angewendet.

Für Anwender D stellt sich nach einer solchen Analyse die Frage, wie die auf Basis dieser ABS gewonnenen Erkenntnisse auf die Preispolitik im realen Markt übertragen werden können. Sicherlich wäre es fahrlässig, die ermittelten Werte im Stile eines Decision-Support-Systems zu interpretieren und direkt in die operative Praxis zu übernehmen. Was die Simulation aber durchaus leisten kann, ist die Identifikation relevanter Stellgrößen einer effektiven Preispolitik und die Richtung möglicher positiver Veränderungen. Außerdem lässt sich aus der Simulation ableiten, ob die aktuelle Preispositionierung eines Anbieters bereits in der Nähe eines lokalen Optimums liegt (Elastizitäten ~ 0) oder ob sich noch Raum für einfache Verbesserungen bietet (Elastizitäten $\neq 0$).

Im gezeigten Fallbeispiel liefert die Simulationsstudie einen quantitativen Beleg dafür, dass die Veränderung der Bepreisung des Vertragstarifs für den Anbieter D durchaus einen positiven Einfluss auf den Umsatz haben kann. Deutlich effizienter ist jedoch die Fokussierung der Preispolitik auf die hochgradig umsatzrelevanten Zeit- und Pauschaltarife und hier insbesondere auf eine mögliche Preissenkung. Die ermittelten Elastizitäten weisen auch im verbesserten Szenario noch auf weitere mögliche Umsatzsteigerungen in dieser Richtung hin.

8.2. Fallstudien zur Optimierung

Ausgehend von dem in Kapitel 8.1 gezeigten Fallbeispiel werden in diesem Kapitel die Mittel der in Kapitel 7 diskutierten simulationsbasierten Optimierung angewendet, um die Preise des Tarifportfolios eines Anbieters zu optimieren. Zur besseren Vergleichbarkeit sei für diese Fallstudie abermals Anbieter D als Gegenstand der Analyse gewählt. Der Ansatz ließe sich aber auch für jeden der anderen Anbieter durchführen. Gesucht ist nun also ein Tarifportfolio, das Anbieter D die Erzielung eines maximalen Umsatzes ermöglicht.

Um zu verhindern, dass eine rein kurzfristig orientierte Umsatzmaximierung dazu führt, initial innerhalb der Mindestvertragslaufzeit verbleibende Kunden durch maximal mögliche

Preise unrealistisch zu benachteiligen, ohne ein nachhaltig umsatzstiftendes Produkt am Markt zu platzieren, sei in diesen Fallstudien auf die initiale Ausstattung der Agenten mit einer Mindestvertragslaufzeit verzichtet. Ein nicht konkurrenzfähig bepreistes Produkt kann somit in der Simulation auch kaum Umsatz generieren und wird sich damit in der Optimierung nicht durchsetzen können. Dies führt unter anderem dazu, dass in dem auf S. 164 dargestellten Ausgangsszenario der Anbieter \mathbb{D} lediglich einen Umsatz von 78.778 € erzielen kann, die Umsätze in Gesamtmarkt betragen in Summe 508.827 €. Zum Ende der Simulationsperioden haben 757 Kunden einen Tarif bei einem der vier Anbieter, während 243 Kunden kein für sie vorteilhaftes Angebot bekommen haben und ihre Nachfrage entsprechend nicht befriedigen.

8.2.1. Einfacher Fall ohne Konkurrenzreaktionen

Zu Beginn sei der Fall betrachtet, in dem Preisanpassungen der zu \mathbb{D} konkurrierenden Anbieter im Verlauf der Simulation nicht möglich sind. Dies scheint vordergründig eine fragwürdige Vereinfachung zu sein, da es über einen betrachteten Zeitraum von 36 Monaten im realen Markt sicherlich zu Reaktionen der Konkurrenz kommen würde. Letztendlich sind die möglichen Reaktionen der Konkurrenz jedoch a priori unbekannt und können aufgrund der komplexen Marktdynamik auch nur schwer antizipiert werden. Es erscheint also durchaus praxisgerecht, die Preise der Konkurrenz als aus deren Sicht optimal anzusehen und diese im Modell als statisch gegeben anzunehmen. Anbieter \mathbb{D} sucht folglich eine Preispolitik, welche die beste Antwort darstellt unter der Annahme, dass die Konkurrenz bereits eine jeweils für sie als optimal angenommene Preispolitik gewählt hat (vgl. z. B. [Mungamuru und Garcia-Molina 2008]). Dieser Ansatz repräsentiert eine eher kurzfristige Planungsperspektive. Zur operativen Umsetzung einer rollierenden Planung kann die Optimierung nach Ablauf einer Planungsperiode unter Einbeziehung der dann wiederum gültigen Konkurrenzpreise erneut durchgeführt und damit zyklisch aktualisiert werden. Später in Kapitel 8.2.2 werden diese Einschränkungen relaxiert und mögliche Konkurrenzreaktionen explizit in die Analyse mit einbezogen.

Die Optimierung mit dem Hybridalgorithmus aus NELs und SPSA verläuft wie in Kapitel 6.2.5 beschrieben mit einem Budget von 50.000 Simulationsläufen, wobei die Startlösung zufällig gewählt wird. Als Optimierungsvariablen fungieren alle vom Anbieter \mathbb{D} beeinflussbaren Preiskomponenten, Tabelle 13 listet deren Ober- (\bar{O}) und Untergrenzen (\bar{U}) sowie Rasterschrittweiten (\bar{W}) für den Optimierungsalgorithmus. Zielfunktion ist weiterhin der kumulierte Umsatz des Anbieters \mathbb{D} über den gesamten Simulationszeitraum von 36 Modellperioden und über alle 1.000 Agenten. Je Szenario werden anhand des Evaluationskriterium2 (vgl. S. 104) zwischen 20 und 500 Replikationen zur Evaluation durchgeführt.

Optimierungsvariable	\bar{U}	\bar{O}	\bar{W}
ⓓ Vertragstarif Minutenpreis	0	1	0,01
ⓓ Vertragstarif Grundgebühr	0	50	0,2
ⓓ Vertragstarif Inklusivminuten	0	60	5
ⓓ Zeittarif Minutenpreis	0	1	0,01
ⓓ Pauschaltarif Grundgebühr	0	50	0,2

Tabelle 13: Grenzen und Rasterschrittweiten der Optimierungsvariablen

Quelle: eigene Darstellung

Ein Optimierungslauf dieser Simulation mit 1.000 Agenten dauert mit der auf Seite 91 beschriebenen Hardware knapp zehn Stunden. Abbildung 52 zeigt einen typischen Verlauf, der insbesondere auch noch zum Ende hin zumindest kleine Verbesserungen erzielt (siehe die oberste Linie). Somit erscheint das Simulationsbudget adäquat dimensioniert.




Abbildung 52: Typischer Optimierungsverlauf

Quelle: eigene Berechnung und Darstellung

Um zu untersuchen, ob verschiedene Optimierungsläufe zu vergleichbaren Ergebnissen kommen, wurden die Optimierung insgesamt fünfmal durchgeführt und die einzelnen Ergebnisse in Tabelle 14 aufgeführt:

	Ergebnisse verschiedener Optimierungsläufe					abgeleitetes Ergebnis
Ⓓ Vertragstarif Minutenpreis	0,14	0,13	0,14	0,13	0,13	0,14
Ⓓ Vertragstarif Grundgebühr	5,81	4,67	4,59	4,44	5,25	5,00
Ⓓ Vertragstarif Inklusivminuten	25	10	20	15	15	15
Ⓓ Zeittarif Minutenpreis	0,20	0,17	0,20	0,18	0,17	0,18
Ⓓ Pauschaltarif Grundgebühr	16,13	16,76	16,54	16,72	16,76	16,50
Umsatz Ⓓ (k€)	247,4	246,4	249,6	250,1	250,7	248,5

Tabelle 14: Ergebnisse der Optimierung

Quelle: eigene Berechnung und Darstellung

Es ergibt sich ein relativ konsistentes Bild, das von allen durchgeführten Simulationsläufen getragen wird. Hieraus sei das in der rechten Spalte gezeigte, als optimal angenommene Ergebnis der Optimierung für die einzelnen Parameterwerte zweckadäquat abgeleitet und der zugehörige Umsatz nachträglich evaluiert.

Im Ergebnis verfolgt der Anbieter Ⓓ die Strategie, durch Kampfpreise seinen Marktanteil bei allen Tarifen ausgewogen gegenüber dem Ausgangsszenario massiv auszubauen. Es entscheiden sich nun im Durchschnitt zweimal mehr Kunden für dessen Pauschaltarif, zehnmal mehr Kunden für den Zeittarif und auch der vorher kaum bediente Vertragstarif erzielt nun eine mit den beiden anderen Tarifen vergleichbare Kundenzahl. Der resultierende Umsatz steigert sich um +215 % auf 248.519 €. Auffallend ist jedoch, dass der umsatzmaximale Preispunkt jeweils nicht durch ein knappes Unterbieten der Konkurrenz erreicht wird, sondern deutlich darunter liegt. Im Ausgangsszenario verblieb noch knapp ein Viertel der Kunden mit unbefriedigter Nachfrage, diese Kunden kann Anbieter Ⓓ mit der neuen Preisstruktur fast vollständig vereinnahmen. Durch deren zusätzliche Umsätze werden die eigentlich „zu günstigen“ Preise für die übrige Kundschaft offensichtlich mehr als kompensiert.

Ein zum Vergleich und zur Plausibilisierung durchgeführter Optimierungslauf mit OptQuest (vgl. Kap. 6.2.2) liefert als Ergebnis eine Lösung mit einem Umsatz von 233.918 € für Anbieter Ⓓ, was abermals deutlich hinter dem Ergebnis des Hybridalgorithmus zurückbleibt.

8.2.2. Iterative Optimierung mit Konkurrenzreaktionen

Im Folgenden werden die restriktiven Einschränkungen aus dem vorigen Kapitel, dass die Konkurrenz nicht durch Preisanpassungen auf die einseitige Optimierung der Preise eines Anbieters reagiert, aufgehoben. Hierzu wird eine sequenzielle, rundenbasierte Optimierung der Anbieter eingeführt, was bedeutet, dass alle Anbieter abwechselnd (in der willkürlich gewählten Reihenfolge Anbieter Ⓓ → Ⓒ → Ⓖ → Ⓐ) ihr Preisportfolio mit kurzfristig fixen Konkurrenzpreisen optimieren. Die als optimal für einen Anbieter ermittelten Werte ersetzen dessen bisherige Preise und gehen als gegebene Konkurrenzpreise in die Optimierung des darauffolgenden Anbieters ein.

Dieser Versuchsaufbau weicht dem Augenschein nach vom realen Markt ab, da dort keine Koordinationsmechanismen bestehen und somit eine parallel laufende, kontinuierliche Preisoptimierung aller Anbieter angenommen werden kann. Trotzdem müssen die Anbieter aber auch hierbei zu einem diskreten Zeitpunkt feste Annahmen über die Preise der Konkurrenz treffen und daraus innerhalb fester Planungszyklen ihre neu optimierten Preise ermitteln. Die Annahme einer sequenziellen Reihenfolge der Preisoptimierung verschiedener Anbieter stellt also keine gravierende Einschränkung dar und sollte nicht zu strukturell unterschiedlichen Ergebnissen führen.

Um die Laufzeit handhabbar zu halten, sei jedem Anbieter für eine Optimierung lediglich ein Budget von 10.000 Simulationsläufen eingeräumt, außerdem sei die Populationsgröße des im Hybridalgorithmus enthaltenen NELS-Algorithmus entsprechend von 20 auf zehn reduziert. Mit dieser Anpassung sind weiterhin mehrere Iterationen des Hybridalgorithmus innerhalb dieses vergleichsweise kleinen Simulationsbudgets möglich.

Abbildung 53 zeigt die Entwicklung der Umsätze der einzelnen Anbieter im Laufe dieser Fallstudie, wobei jeweils der Umsatz nach einer Optimierung farblich markiert ist. Wenig überraschend geht eine solche einseitige Optimierung jeweils zulasten der anderen Anbieter. Ihre Umsätze fallen sukzessive, bis durch eine Optimierung wieder eine konkurrenzfähige Wettbewerbsposition der Bepreisung des jeweiligen Produktportfolios hergestellt wird. Da die Startsituation konstruiert ist, sind die ersten Optimierungen reihum notwendig, um einen näherungsweisen Gleichgewichtszustand im Markt zu erreichen; dies ist augenscheinlich nach zwei Umläufen der Fall.

Nach dem Ablauf von 16 Optimierungsrunden (bzw. vier Umläufen der vier Anbieter) haben sich die in Tabelle 15 aufgelisteten Preise für die Produktportfolios der Anbieter eingestellt. Es zeigt sich, dass die Anbieter sehr unterschiedliche optimale Preisstrategien gefunden haben. Während Anbieter C und auch Anbieter B durch eine moderate Preisgestaltung des Vertragstarifs Zuwächse bei den Kundenzahlen verbuchen können, verwendet Anbieter A eine entgegengesetzte Strategie und schöpft bei sinkenden Kundenzahlen durch hohe Preise seine Umsätze ab. Die Zeit- und Pauschaltarife hingegen werden entsprechend der jeweiligen Attraktivität der Anbieter konkurrenzfähig bepreist. Dies zeigt, dass bei einfach strukturierten Tarifen lediglich ein Preiswettbewerb stattfinden kann, während sich bei komplexeren Tarifwerken wie einem Vertragstarif einzelne Nischen im Markt bilden können.




Abbildung 53: Umsätze der Anbieter im Laufe der iterativen Optimierung

Quelle: eigene Berechnung und Darstellung

Die im final eingeschwungenen Zustand erzielten Umsätze der Anbieter zeigen außerdem deutlich, wie die Kunden von der intensiven Wettbewerbssituation profitieren (vgl. Tabelle 16): Zum einen ist der Gesamtumsatz aller Anbieter von 508,8 k€ im Ausgangsszenario auf 184,3 k€ gesunken, was entsprechend äquivalent für die von den Kunden zu tragenden Kosten gilt. Außerdem hat das signifikant gesunkene Preisniveau auch ermöglicht, dass nun alle Kunden einen für sie passenden Tarif finden.

Anbieter	Tariftyp	Minutenpreis	Grundgebühr	Inklusivminuten
A	Vertragstarif	0,54 €	3,90 €	53
	Zeittarif	0,08 €	-	-
	Pauschaltarif	-	7,00 €	∞
B	Vertragstarif	0,22 €	3,80 €	49
	Zeittarif	0,07 €	-	-
	Pauschaltarif	-	8,30 €	∞
C	Vertragstarif	0,06 €	2,60 €	44
	Zeittarif	0,06 €	-	-
	Pauschaltarif	-	6,30 €	∞
D	Vertragstarif	0,15 €	33,30 €	37
	Zeittarif	0,07 €	-	-
	Pauschaltarif	-	5,10 €	∞

Tabelle 15: Endszenario der iterativen Optimierung

Quelle: eigene Berechnung und Darstellung

Anbieter	Tariftyp	Umsatz (k€)		Anzahl Kunden	
		vorher	nachher	vorher	nachher
A	Vertragstarif	57,9	10,7	113	67
	Zeittarif	38,4	26,1	148	197
	Pauschaltarif	60,2	34,3	33	139
	<i>total</i>	156,5	71,0	293	403
B	Vertragstarif	32,3	13,6	21	77
	Zeittarif	28,9	29,0	85	220
	Pauschaltarif	79,4	29,2	61	97
	<i>total</i>	140,7	71,8	167	395
C	Vertragstarif	5,5	8,4	6	46
	Zeittarif	2,0	7,5	12	52
	Pauschaltarif	125,4	9,6	172	42
	<i>total</i>	132,9	25,5	190	140
D	Vertragstarif	2,1	0,0	2	0
	Zeittarif	9,4	6,6	29	25
	Pauschaltarif	67,3	9,3	75	38
	<i>total</i>	78,8	16,0	106	62
<i>total</i>		508,8	184,3	757	1000

Tabelle 16: Umsatz und Kunden vor bzw. nach der iterativen Optimierung

Quelle: eigene Berechnung und Darstellung

8.2.3. Parallele Optimierung mit Konkurrenzreaktionen

Im Gegensatz zum vorigen Kapitel sei nun die feste sequenzielle Reihenfolge der Optimierungen der Anbieter durch eine parallele Optimierung ersetzt. Dies bedeutet, dass

ausgehend von den Preisen der Vorrunde jeder Anbieter für sich eine separate Optimierung durchführt. Zusammen bilden die so jeweils (sub-)optimierten Preise das Preisschema der nächsten Runde. Prinzipiell wäre es hierbei auch möglich, dass Anbieter einzelne Runden auslassen, um so einen längeren Planungszyklus im Modell abzubilden. Erwartungsgemäß würde dies aber nur zu einer Verlangsamung der sich einstellenden Effekte führen.




Abbildung 54: Umsätze der Anbieter im Laufe der parallelen Optimierung

Quelle: eigene Berechnung und Darstellung

Wie Abbildung 54 zeigt, ist die Einschwingphase bei der parallelen Optimierung deutlich kürzer. Schon nach einer Optimierungsrunde sind die im Ausgangsszenario gültigen Preis-

schemata für alle Anbieter obsolet und wurden durch kompetitive Varianten ersetzt. Es stellt sich bereits nach vier Runden ein Gleichgewicht ein, von dem ausgehend in den weiteren Runden keiner der Anbieter seine Umsatzsituation mehr merklich verbessern kann.

Nach dem Ablauf von wiederum insgesamt 16 Optimierungsrunden haben sich die in Tabelle 17 aufgelisteten Preise für die Produktportfolios der Anbieter eingestellt. Diese sind teilweise dem Ergebnis der iterativen Optimierung (vgl. Tabelle 15) ähnlich, teilweise zeigen sie aber auch signifikant unterschiedliche Preisstrategien der Anbieter. Besonders augenscheinlich wird dies beim Vertragstarif von Anbieter A, der bei der iterativen Optimierung noch eine auffällige Hochpreisstrategie gewählt hatte, sich nun aber in die Preisschemata der übrigen Anbieter einfügt. Letztendlich verdeutlicht dies, dass in dem komplexen simulierten Markt keine natürlich vorgegebenen Attraktionspunkte der Positionierung existieren, sondern sich je nach den Preisaktionen der Wettbewerber unterschiedliche Pfade der Preisentwicklung einstellen können, die zu unterschiedlichen Gleichgewichten führen. Tabelle 18 zeigt jedoch, dass auch der hierbei eingeschlagene, von der iterativen Optimierung in Teilen deutlich abweichende Pfad zu ähnlichen optimierten Umsätzen der Anbieter führt.

Konsistent zur erwarteten Marktmechanik sind die sich einstellenden Gesamtumsätze bei der parallelen Optimierung (170,2 k€) etwas unterhalb der iterativen Optimierung (184,3 k€) angesiedelt. Hintergrund ist, dass die parallele Optimierung einen konstant hohen Wettbewerbsdruck auf alle Anbieter ausübt, während im iterativen Fall zumindest bei der Optimierung des jeweiligen Anbieters aus dessen Sicht für eine Runde kein kompetitiver Wettbewerb herrscht.

Anbieter	Tariftyp	Minutenpreis	Grundgebühr	Inklusivminuten
A	Vertragstarif	0,06 €	3,90 €	29
	Zeittarif	0,07 €	-	-
	Pauschaltarif	-	7,30 €	∞
B	Vertragstarif	0,05 €	4,20 €	53
	Zeittarif	0,09 €	-	-
	Pauschaltarif	-	7,00 €	∞
C	Vertragstarif	0,04 €	2,70 €	43
	Zeittarif	0,04 €	-	-
	Pauschaltarif	-	3,50 €	∞
D	Vertragstarif	0,04 €	3,00 €	39
	Zeittarif	0,04 €	-	-
	Pauschaltarif	-	6,00 €	∞

Tabelle 17: Endszenario der parallelen Optimierung

Quelle: eigene Berechnung und Darstellung

Anbieter	Tariftyp	Umsatz (k€)		Anzahl Kunden	
		vorher	nachher	vorher	nachher
A	Vertragstarif	57,9	20,2	113	87
	Zeittarif	38,4	20,7	148	184
	Pauschaltarif	60,2	24,6	33	90
	<i>total</i>	156,5	65,5	293	361
B	Vertragstarif	32,3	24,7	21	97
	Zeittarif	28,9	15,2	85	146
	Pauschaltarif	79,4	25,5	61	106
	<i>total</i>	140,7	65,3	167	349
C	Vertragstarif	5,5	6,8	6	49
	Zeittarif	2,0	7,2	12	77
	Pauschaltarif	125,4	9,2	172	79
	<i>total</i>	132,9	23,2	190	205
D	Vertragstarif	2,1	4,7	2	20
	Zeittarif	9,4	6,0	29	43
	Pauschaltarif	67,3	5,5	75	22
	<i>total</i>	78,8	16,3	106	84
<i>total</i>		508,8	170,2	757	1000

Tabelle 18: Umsatz und Kunden vor bzw. nach der parallelen Optimierung

Quelle: eigene Berechnung und Darstellung

8.3. Diskussion der Fallstudien

Die in Kapitel 8.1 gezeigte Fallstudie zur Simulation hat prinzipiell gezeigt, wie die in Kapitel 4 entworfene agentenbasierte Simulation zur Gewinnung wirtschaftswissenschaftlich relevanter und interessanter Erkenntnisse verwendet werden kann. Entsprechend hat sie aber auch die Notwendigkeit eines methodisch strukturierten Vorgehens verdeutlicht, um die notwendigen Ressourcen zur Simulation für den praktischen Einsatz handhabbar zu halten. Genau dieses strukturierte Vorgehen wird mit der simulationsbasierten Optimierung in Kapitel 8.2 bereitgestellt und damit werden die Einsatzmöglichkeiten der ABS erheblich erweitert.

Trotzdem gilt, dass für die Interpretation und Anwendung der mit einer solchen Simulations- und Optimierungsstudie gewonnenen Erkenntnisse in einer realen Marktsituation eine kritische Hinterfragung der verwendeten Methodik notwendig ist. Insbesondere muss sich der Anwender zweier Abbildungen bewusst sein, die im Laufe der Arbeit prinzipiell stattfinden. Zum einen handelt es sich hierbei um die Abbildung des realen Marktes im Modell, diese beinhaltet in der Regel Vereinfachungen und Abstrahierungen gegenüber dem realen Markt, wie z. B. die in Kapitel 4.2 modellierte Tarifstruktur nicht die Komplexität der am Markt vorgefundenen Tarife abbilden kann. Zum anderen ist aber auch die Übertragung der Simulations- und Optimierungsergebnisse zurück in den realen Markt eine Abbildung, z. B. ist nicht ausgeschlossen, dass die eingangs vor-

genommenen Vereinfachungen ein modelliertes System geschaffen haben, dessen Ergebnisse nicht mehr auf das reale System übertragbar sind. Beide Aspekte zusammengenommen unterstreichen die Notwendigkeit, die aus dem Modell gewonnenen Erkenntnisse kritisch zu beurteilen und nur in Form einer geeigneten Interpretation zurück auf den realen Markt zu übertragen. Diese theoretisch begründete Überlegung definiert insbesondere auch die engen Grenzen der Anwendung der Ergebnisse der im Rahmen dieser Arbeit durchgeführten Fallstudien.

Jenseits des Marketings im Speziellen und der Betriebswirtschaftslehre im Allgemeinen zeigen die Fallstudien, wie sich ein solches agentenbasiertes Modell mit der darauf aufbauenden Optimierung als ein Werkzeug für die spieltheoretische Forschung anbietet. In diesem Sinne sind die Anbieter als Spieler zu sehen, die in einem Spiel mit komplexen Wirkungszusammenhängen die für sie optimale Spielstrategie suchen. In einem solchen Spiel lassen sich erst durch eine Simulation die Ausprägung und Wahrscheinlichkeiten verschiedener Spielergebnisse auf Basis der Aktionen der einzelnen Spieler beurteilen. Die Optimierung ermöglicht es, gute Strategien zu identifizieren und deren Qualität in einem kompetitiven Umfeld zu testen.

9. Schlussbetrachtung

Die vorliegende Arbeit stellt eine grundlegende Aufarbeitung der agentenbasierten Simulation (ABS) und der simulationsbasierten Optimierung (SBO) dar. Sie verzahnt diese beiden wissenschaftlichen Bereiche zu einer analytischen Methodik, mit deren Hilfe praxisnahe wirtschaftliche Entscheidungen quantitativ unterstützt werden können. Damit ist die Arbeit dem Operations Research³⁴ zuzurechnen. Wenngleich die beiden einzelnen Bereiche für sich betrachtet bereits eingehend erforscht wurden, bildet deren Verzahnung ein relevantes, jedoch bisher kaum beachtetes wissenschaftliches Forschungsfeld.

9.1. Ansatz und Methodik

Anhand des deutschen Mobilfunkmarktes wurde im ersten Teil dieser Arbeit eine agentenbasierte Modellierung entwickelt, welche die Kunden mit ihrem charakteristischen Entscheidungsverhalten sowie die im Wettbewerb stehenden Anbieter abbildet.

Da das Entscheidungsverhalten der Kunden die determinierende Mechanik innerhalb des realen Marktes wie auch in der Simulation darstellt, wurde hier ein besonderes Augenmerk auf die realitätsnahe Modellierung gelegt. Auf Basis einer Vielzahl empirischer Studien wurden die möglichen Entscheidungsattribute der Kunden im Mobilfunkmarkt identifiziert und zu einer Menge an übergreifend als relevant einzustufenden Attributen für das Modell verdichtet: Nachfragebefriedigung, entstehende Kosten, Attraktivität des Anbieters, Einfluss des sozialen Netzwerks und Treue zum bisherigen Anbieter. Diese Attribute wurden mithilfe einer aus Discrete-Choice-Modellen bekannten additiven teilstochastischen Nutzenfunktion zusammengefasst. Über eine unterschiedliche Gewichtung der Attribute wurden unterschiedliche Typen von Kunden abgebildet. Die Nutzenfunktion wurde schließlich dazu verwendet, um die im Verlauf der Simulation zur Auswahl stehenden Entscheidungsalternativen zu bewerten und aus Sicht des jeweiligen Kunden die bestmögliche Alternative zu identifizieren.

Die Tarife der Anbieter stellen neben dem Entscheidungsverhalten der Kunden das zweite strukturelle Kernelement des Mobilfunkmarktes dar, da durch sie die für einen Kunden zur Auswahl stehenden Entscheidungsalternativen charakterisiert werden. Im Modell wurde die unübersichtliche Vielzahl von Tarifen des realen Marktes auf die drei Grundtypen Vertrags-tarif, Zeittarif und Pauschaltarif zurückgeführt. Anhand dieser Tarif-Grundtypen lässt sich ein Großteil der am Markt angebotenen Tarife im Modell repräsentieren. Die konkreten Preise der Tarife stellten dabei die Parameter der Simulation dar.

Ziel der so erlangten Modellierung und Simulation des Mobilfunkmarktes war die Analyse von Fragestellungen des Preismanagements. Durch Festlegung eines Preisschemas je Anbieter und anschließender Simulation lassen sich die Auswirkungen der gewählten Preise

³⁴ Für eine abgrenzende Definition von „Operations Research“ siehe <http://www.scienceofbetter.org/what/>, abgerufen am 7. November 2010.

auf die Kundenzahlen und Umsätze der einzelnen Anbieter transparent machen. Mehr noch: Durch Variation der Preisparameter eines Anbieters ließen sich Stoßrichtungen identifizieren, in denen sich der Markt positiv für den Anbieter entwickelt. Wie gezeigt wurde, stößt dieser Ansatz jedoch schnell an seine Grenzen. Aufgrund der Komplexität der Aufgabe wird ein strukturiertes Vorgehen zur Optimierung unumgänglich.

Durch die intensive Beschäftigung mit der ABS haben sich verschiedene Aspekte herauskristallisiert, welche die Motivation für den wissenschaftlichen Einsatz dieses Werkzeugs durchaus kritisch erscheinen lassen. Häufig wird eine ABS nach Einschätzung des Autors weniger aus wissenschaftlichen, sondern eher aus oberflächlich-ästhetischen Gründen gewählt. Auf den ersten Blick stellt die ABS einen sehr natürlichen Weg dar, Zusammenhänge speziell aus sozial geprägten Systemen in ein Modell zu übertragen und im Rahmen der Simulation zu analysieren. Solche Ansätze erreichen aber schnell einen Grad der Komplexität der resultierenden Modellierung, der eine geeignete Interpretation der Simulationsergebnisse bezogen auf das ursprüngliche reale System kaum möglich macht. Entsprechend finden sich auch bisher nur wenige Arbeiten in der wissenschaftlichen Literatur, die das Potenzial der ABS ausschöpfen, sowohl bezogen auf einen strukturell geeigneten Anwendungsfall (Markt geprägt von Heterogenität, Netzwerkeffekten und Emergenz) als auch auf eine geeignete Modellierung, welche die Ableitung relevanter Erkenntnisse erlaubt.

Auch das in dieser Arbeit entworfene Simulationsmodell des Mobilfunkmarktes erfüllt die genannten Kriterien nicht uneingeschränkt. Zwar ist der zugrunde liegende Mobilfunkmarkt strukturell prädestiniert für die Modellierung als ABS, aber der gewählte Detaillierungsgrad im Modell reicht nicht aus, um das weitverzweigte Marktverhalten detailgetreu nachzubilden. Die aus dem Ablauf der Simulation ableitbaren Erkenntnisse haben deshalb, konsistent z. B. zu den zugrunde gelegten Tarifcharakteristika und Entscheidungsattributen, lediglich eine generische Aussagekraft. Das Ziel der Modellierung, ein Anwendungsfeld für die darauffolgend diskutierten Methoden der simulationsbasierten Optimierung zu erstellen, erfüllt das Modell damit aber vollauf.

Im zweiten Teil der Arbeit wurde die simulationsbasierte Optimierung als ein Werkzeug vorgestellt, mit dem sich die freien Parameter einer ABS nach einem definierten Zielkriterium optimieren lassen. Dieses Optimierungsproblem ist aufgrund stochastischer Einflüsse auf die Simulation und der daraus resultierenden stochastischen Verteilung der aus dem Simulationsablauf berechneten Zielfunktionswerte als schwierig genug anzusehen, dass selbst renommierte generalistische Standardverfahren wie das kommerzielle OptQuest vor einer ernstzunehmenden Herausforderung stehen. Aufgrund der emergenten Struktur der Simulationsabläufe einer ABS können kaum strukturelle Annahmen zum Optimierungsproblem getroffen werden, die sich durch einen geeigneten spezialisierten Algorithmus ausnutzen ließen. Einzig die Annahme, dass der Lösungsraum von monotonen Bereichen geprägt ist, die durch Unstetigkeiten unterbrochen werden, kann als übergreifend gültig angesehen werden. Entsprechend zeigten sich auch diejenigen Optimierungsverfahren als geeignet, die im Rahmen einer Diversifikation (Globalsuche) möglichst vielversprechende Bereiche im Lösungsraum identifizieren und innerhalb dieser Bereiche dann mit einer

Intensivierung (Lokalsuche) die besten Lösungen finden. Da mehrere Replikationen notwendig sind, um eine aussagefähige, weitgehend störungsfreie Bewertung einer Lösung zu erhalten, spielt auch die Methodik zur Allokation der Anzahl Replikationen auf die einzelnen untersuchten Lösungen eine entscheidende Rolle für die Effizienz des eingesetzten Verfahrens. Entsprechend wurden verschiedene Evaluationskriterien entworfen, die den Vergleich zweier Lösungen unter diesen Rahmenbedingungen ermöglichen. Die Kriterien bedienen sich etablierter statistischer Verfahren wie dem t-Test und dem Wilcoxon-Rangsummentest und ermitteln darauf basierend die Anzahl der benötigten Replikationen für die Evaluation einer konkreten Lösung im Rahmen der Optimierung.

Vorgestellt wurden drei Verfahren zur simulationsbasierten Optimierung. Der Algorithmus SPSA vollzieht eine stochastische Gradientenoptimierung und ist das wohl aktuell am weitesten verbreitete Verfahren für diesen Zweck in der wissenschaftlichen Literatur. Demgegenüber wurde der evolutionäre Algorithmus NELS im Rahmen dieser Arbeit entwickelt. Dieser zeichnet sich durch seinen charakteristischen Ansatz zur Bereinigung der Population in der Nachbarschaft guter Lösungen aus und adressiert damit speziell die gezeigten Erfordernisse der Optimierung einer komplexen ABS. Die Kombination beider Verfahren in einem Hybridalgorithmus bindet schließlich die bekannten Fähigkeiten des SPSA zur lokalen Verbesserung einzelner Lösungen der Population in den übergreifend agierenden NELS ein und vereint so die Stärken beider Verfahren.

Beim umfassenden experimentellen Vergleich der Verfahren stach insbesondere das Hybridverfahren für den praktischen Einsatz im Rahmen einer ABS hervor, da es eine sehr gute Lösungsqualität mit einer hohen Zuverlässigkeit paart, gute Lösungen auch zu finden. Das Verfahren NELS allein konnte nicht die durchschnittliche Lösungsqualität des Hybridalgorithmus erreichen. Der SPSA zeigte zwar in der Spitze eine überzeugende Lösungsqualität, hatte aber in der implementierten Standardform Schwächen beim vereinzelt Steckenbleiben in schlechten Bereichen des Lösungsraumes, was in einer hohen Varianz der Optimierungsergebnisse resultierte. Augenscheinlich war die vergleichsweise gute Leistungsfähigkeit der zum Vergleich verwendeten globalen Zufallssuche GRS, von der sich keines der Verfahren extrem absetzen konnte. OptQuest als eigentlich gedachter Benchmark erzielte sogar nur eine marginal bessere Lösungsfähigkeit als der GRS auf den Beispielen.

9.2. Implikationen für die Anbieter im Mobilfunkmarkt

Die Erkenntnisse aus den Fallstudien bestätigen die landläufige Hypothese, dass die frühzeitige Erschließung eines signifikanten Marktanteils den langfristigen Markterfolg eines Anbieters sichert. Wie eingehend analysiert wurde, liegt der Grund hierfür in Netzwerkeffekten, die einem Anbieter Vorteile (bzw. auch Nachteile) gegenüber dem Wettbewerb verschaffen und dadurch den Markterfolg eines etablierten Anbieters stabilisieren können. Ein Anbieter mit wirksamen Netzwerkeffekten kann sogar ein Premium am Markt erzielen, indem er seine Produkte oberhalb des im Wettbewerb jeweils gerechtfertigten Preises platziert und trotzdem seine Kundenbasis halten bzw. ausbauen kann. Umgekehrt muss ein Anbieter mit schwach wirkenden Netzwerkeffekten (d. h. mit geringem Marktanteil oder zu breit ge-

streutem Kundenportfolio) Preisabschläge in Kauf nehmen, um den Kunden ein konkurrenzfähiges Angebot unterbreiten zu können.

Anbieter, die das Wissen um Netzwerkeffekte im realen Markt zielgerichtet für sich nutzen können, akquirieren mehr Kunden, ohne durch Preissenkungen ihre Umsätze gefährden zu müssen. Im Optimalfall kann ein Anbieter eine abgegrenzte Zielgruppe an Kunden identifizieren, die eine überdurchschnittliche Vernetztheit untereinander vermuten lässt, und adressiert diese Gruppe mit einem speziellen Angebot. Eine solche vernetzte Zielgruppe kann im selben Wohnort begründet sein, in ihrer ethnischen Herkunft, in sozialen Faktoren (wie z. B. der Zugehörigkeit zu einer Gewerkschaft oder einem Verein) oder auch nur in einer Affinität zur selben Supermarkt- oder Drogeriekette. Ein in diesem Sinne vorbildliches Beispiel liefert der Mobilfunktarif „Ay Yildiz“³⁵ des Anbieters E-Plus auf dem deutschen Mobilfunkmarkt, der mit einem türkischen Namen, türkischer Hotline und speziellen Tarifen für Telefonate in die Türkei aufwartet. Für einen derart kohärent auf die Zielgruppe türkischstämmiger Einwohner ausgerichteten Tarif kann erwartet werden, dass durch den Katalysator der Netzwerkeffekte mehr Kunden angesprochen werden, als durch reine Preismaßnahmen erreichbar wären.

9.3. Ausblick für weitere Forschung

Für die beiden Kernbereiche dieser Arbeit, die agentenbasierte Simulation und die simulationsbasierte Optimierung, wurden bereits in den Kapiteln 3.4 bzw. 7.5 ausführliche Ausblicke zu weiteren möglichen Forschungsrichtungen gegeben. Verschiedene Erweiterungen speziell des Simulationsmodells wurden in Kapitel 4.7 diskutiert. In Kapitel 8.3 wurden darüber hinaus praktische Einsatzszenarien für die im Rahmen dieser Arbeit lediglich prototypisch verwendeten simulationsbasierten Optimierungsverfahren aufgezeigt. An dieser Stelle verbleibt also lediglich noch, die vorliegende Arbeit in einem breiteren Kontext einzuordnen.

Alle bisher betrachteten Fallstudien gehen davon aus, dass das Angebot der Mobilfunkbetreiber unbegrenzt ist und gegebenenfalls durch einen Netzausbau angepasst werden kann, sodass keine Einschränkungen bestehen, jede am Markt generierte Nachfrage auch zu bedienen. Würde man die Kosten hierfür im Modell berücksichtigen, ergäben sich neue Zielsetzungen für die Optimierung aus Sicht des Anbieters. Die Frage wäre dann, welcher maximale Umsatz bei gegebener Netzkapazität möglich ist und wie dieser realisiert werden kann (typisch für Fragestellungen des klassischen Revenue Managements, vgl. [Klein und Steinhardt 2008]) oder welcher maximale Gewinn (als Umsatz minus Kosten) erzielt werden kann, wenn die Kapazität bei überschreitender Nachfrage erweitert würde.

Die bereits ausgeführte Tatsache, dass die Optimierung im Kontext der ABS bisher keine Rolle spielt, zeigt das zukünftige Entwicklungspotenzial des in dieser Arbeit vorgestellten Optimierungsansatzes. Viele der in Kapitel 3.2 vorgestellten Anwendungen würden beispielsweise von einer Optimierungsmöglichkeit profitieren. Damit könnten nicht nur Ein-

³⁵ <http://www.ayyildiz.de/>, abgerufen am 28. November 2010.

blicke in einzelne Abläufe einer Simulation erlangt, sondern optimale Konfigurationen der Simulation identifiziert und auf das reale System übertragen werden. Durch die in dieser Arbeit detailliert beschriebenen Verfahren wäre eine solche Erweiterung mit begrenztem Aufwand leistbar, insbesondere wenn Simulationsumgebungen zum Einsatz kommen, die eine programmtechnische Steuerung mehrerer Simulationsabläufe von außerhalb der Simulation ermöglichen.

Die Analyse der Optimierungsverfahren in dieser Arbeit erfolgte zwar mit einem Fokus auf die Eignung für die Optimierung einer ABS, letztendlich ist die Simulation aber aus Sicht der Optimierung eine intransparente „Blackbox“, die sich nur durch einzelne Zielfunktionsauswertungen erschließt. Somit sind die in dieser Arbeit gewonnenen Erkenntnisse zumindest auf diejenigen simulationsbasierten Problemstellungen übertragbar, die einen ähnlich strukturierten, komplexen Lösungsraum besitzen wie eine ABS. Erwartungsgemäß trifft dies auf eine Vielzahl von Simulationen zu. Häufig werden z. B. miteinander verknüpfte Prozesse simuliert, wie bei Lieferketten im Supply Chain Management oder bei Produktionsstraßen in Fabriken. Selbst bei der Simulation physikalischer Prozesse dürfte eine solche Struktur des Lösungsraumes nicht ungewöhnlich sein.

Auf den in Kapitel 8.3 hingewiesenen Zusammenhang mit der Spieltheorie wurde in der vorliegenden Arbeit nicht näher eingegangen. Interessant wäre zu untersuchen, inwiefern die ABS helfen kann, die häufig mit abstrakten Annahmen zu den Strategien der Spieler arbeitende Spieltheorie um ein Werkzeug zu ergänzen, mit dem Spielzüge abseits der Theorie einfach modellierbar sind. Im gezeigten Beispiel wären die Anbieter im oligopolistischen Mobilfunkmarkt typische Spieler, die als Agenten modelliert auf ihre jeweiligen Strategien in der Simulation gegenseitig reagieren könnten.

Der Eindruck, dass die vorliegende Arbeit kein abschließendes Bild der Forschungsfelder der agentenbasierten Simulation und der simulationsbasierten Optimierung bietet, ist aus Sicht des Autors sowohl zutreffend als auch berechtigt. Beide Bereiche entwickeln sich weiterhin lebhaft, und für ihre Verzahnung ist mit dieser Arbeit ein initialer Schritt geleistet. Die zukünftige Forschung muss zeigen, welche relevanten Anwendungen mit praktischem Nutzwert auf Basis des vorgelegten theoretischen Grundgerüsts erstellt werden können.

10. Literaturverzeichnis

- van Aart, C. (2005): *Organizational Principles for Multi-agent Architectures*. Birkhäuser, Basel.
- Adenso-Díaz, B. und Laguna, M. (2006): Fine-tuning of algorithms using fractional experimental designs and local search. *Operations Research* 54(1), S. 99–114.
- Alexopoulos, C. (2006): Statistical estimation in computer simulation. In: S. G. Henderson und B. L. Nelson (Hrsg.), *Handbooks in Operations Research and Management Science, Volume 13: Simulation*. North-Holland, Amsterdam, S. 193–223.
- Alkhamis, T. M. und Ahmed, M. A. (2004): Simulation-based optimization using simulated annealing with confidence interval. In: R. G. Ingalls, M. D. Rossetti, J. S. Smith und B. A. Peters (Hrsg.), *Proceedings of the Winter Simulation Conference (WSC 2004)*, Washington. Association for Computing Machinery, New York, S. 514–519.
- Alrefaei, M. H. und Andradottir, S. (1999): A simulated annealing algorithm with constant temperature for discrete stochastic optimization. *Management Science* 45(5), S. 748–764.
- Andradottir, S. (1998): Simulation optimization. In: J. Banks (Hrsg.), *Handbook of Simulation: Principles, Methodology, Advances, Applications, and Practice*. Wiley, New York, S. 307–333.
- Andradottir, S. und Prudius, A. A. (2009): Balanced explorative and exploitative search with estimation for simulation optimization. *INFORMS Journal on Computing* 21(2), S. 193–208.
- Andradóttir, S. (2006): An overview of simulation optimization via random search. In: S. G. Henderson und B. L. Nelson (Hrsg.), *Handbooks in Operations Research and Management Science, Volume 13: Simulation*. North-Holland, Amsterdam, S. 617–631.
- Arciero, L., Biancotti, C., D’Aurizio, L. und Impenna, C. (2009): Exploring agent-based methods for the analysis of payment systems: A crisis model for starlogo TNG. *Journal of Artificial Societies and Social Simulation* 12(1).
- Arthur D. Little/Exane BNP Paribas (2007): Telecom operators: Caution – work ahead.
http://www.adlittle.de/studien.html?&no_cache=1&category=21&view=187, abgerufen am 28. Dezember 2010.
- Avlonitis, G. J. und Indounas, K. A. (2005): Pricing objectives and pricing methods in the services sector. *Journal of Services Marketing* 19(1), S. 47–57.
- Axelrod, R. (1984): *The Evolution of Cooperation*. Basic Books, New York.
- Axelrod, R. (2006): Agent-based modeling as a bridge between disciplines. In: L. Tesfatsion und K. L. Judd (Hrsg.), *Handbook of Computational Economics, Volume 2: Agent-based Computational Economics*. Elsevier, Amsterdam, S. 1565–1584.
- Axelrod, R. und Cohen, M. D. (1999): *Harnessing Complexity: Organizational Implications of a Scientific Frontier*. Free Press, New York.
- Axtell, R., Axelrod, R., Epstein, J. M. und Cohen, M. D. (1996): Aligning simulation models: A case study and results. *Computational and Mathematical Organization Theory* 1(2), S. 123–141.
- Balci, O. (1998): Verification, validation, and testing. In: J. Banks (Hrsg.), *Handbook of Simulation: Principles, Methodology, Advances, Applications, and Practice*. Wiley, New York, S. 335–393.
- Bankes, S. C. (2002): Agent-based modeling: A revolution? *Proceedings of the National Academy of Sciences* 99, S. 7199–7200.
- Barabási, A.-L. und Albert, R. (1999): Emergence of scaling in random networks. *Science* 286(5439), S. 509–512.
- Barnes, S., Golden, B. und Wasil, E. (2010): MRSA transmission reduction using agent-based modeling and simulation. *INFORMS Journal on Computing* 22(4), S. 635–646.
- Barr, R. S., Golden, B. L., Kelly, J. P., Resende, M. G. C. und Stewart, W. R. (1995): Designing and reporting on computational experiments with heuristic methods. *Journal of Heuristics* 1(1), S. 9–32.

- Barton, R. R. und Meckesheimer, M. (2006): Metamodel-based simulation optimization. In: S. G. Henderson und B. L. Nelson (Hrsg.), *Handbooks in Operations Research and Management Science, Volume 13: Simulation*. North-Holland, Amsterdam, S. 535–574.
- Bartz-Beielstein, T. (2006): *Experimental Research in Evolutionary Computation: The New Experimentalism*. Springer, Berlin.
- Bauer, B., Müller, J. P. und Odell, J. (2001): Agent UML: A formalism for specifying multiagent interaction. In: P. Ciancarini und M. J. Wooldridge (Hrsg.), *Agent-oriented Software Engineering: First International Workshop (AOSE 2000)*. Springer, Berlin, S. 91–103.
- Bauer, B. und Odell, J. (2005): UML 2.0 and agents: How to build agent-based systems with the new UML standard. *Engineering Applications of Artificial Intelligence* 18(2), S. 141–157.
- Baydar, C. (2003): Agent-based modeling and simulation of store performance for personalized pricing. In: S. Chick, P. J. Sanchez, D. Ferrin und D. J. Morrice (Hrsg.), *Proceedings of the Winter Simulation Conference (WSC 2003)*, New Orleans. Association for Computing Machinery, New York, S. 1759–1764.
- Bechhofer, R. E., Santner, T. J. und Goldsman, D. M. (1995): *Design and Analysis of Experiments for Statistical Selection, Screening and Multiple Comparisons*. Wiley, New York.
- Benenson, I. und Torrens, P. (2004): *Geosimulation: Automata-based Modeling of Urban Phenomena*. Wiley, Chichester.
- Bergenti, F., Gleizes, M.-P. und Zambonelli, F. (Hrsg.) (2004): *Methodologies and Software Engineering for Agent Systems*. Kluwer Academic Publishers, Boston.
- Bettman, J. R., Johnson, E. J. und Payne, J. W. (1991): Consumer decision making. In: T. S. Robertson und H. H. Kassarian (Hrsg.), *Handbook of Consumer Behaviour*. Prentice Hall, London, S. 50–84.
- Beyer, H.-G. (2000): Evolutionary algorithms in noisy environments: Theoretical issues and guidelines for practice. *Computer Methods in Applied Mechanics and Engineering* 186(2-4), S. 239–267.
- Biethahn, J. und Nissen, V. (1994): Combinations of simulation and evolutionary algorithms in management science and economics. *Annals of Operations Research* 52(4), S. 181–208.
- Birke, D. (2009): The economics of networks: A survey of the empirical literature. *Journal of Economic Surveys* 23(4), S. 762–793.
- Birke, D. und Swann, G. M. P. (2005): Social networks and choice of mobile phone operator. *Occasional Paper Series 2005-14*, Industrial Economics Division, Nottingham University Business School.
- Boesel, J., Nelson, B. L. und Ishii, N. (2003): A framework for simulation-optimization software. *IIE Transactions* 35(3), S. 221–229.
- Boesel, J., Nelson, B. L. und Kim, S.-H. (2003): Using ranking and selection to ‘clean up’ after simulation optimization. *Operations Research* 51(5), S. 814–825.
- Bonabeau, E. (2002): Agent-based modeling: Methods and techniques for simulating human systems. *Proceedings of the National Academy of Sciences* 99(3), S. 7280–7287.
- Bonabeau, E. (2004): The perils of the imitation age. *Harvard Business Review* 82(6), S. 45–54.
- Bonabeau, E. (2007): Understanding and managing complexity risk. *MIT Sloan Management Review* 48(4), S. 62–68.
- Bossel, H. (2004): *Systeme, Dynamik, Simulation*. Books on Demand, Norderstedt.
- Bossomaier, T. (2008): Cellular automata. In: Y. Shan und A. Yang (Hrsg.), *Applications of Complex Adaptive Systems*. IGI Publishing, Hershey, S. 57–84.
- Bower, J., Bunn, D. W. und Wattendrup, C. (2001): A model-based analysis of strategic consolidation in the German electricity industry. *Energy Policy* 29(12), S. 987–1005.

- Branke, J., Chick, S. E. und Schmidt, C. (2005): New developments in ranking and selection: An empirical comparison of the three main approaches. In: M. E. Kuhl, N. M. Steiger, F. B. Armstrong und J. A. Joines (Hrsg.), *Proceedings of the Winter Simulation Conference (WSC 2005)*, Orlando. Association for Computing Machinery, New York, S. 708–717.
- Branke, J., Chick, S. E. und Schmidt, C. (2007): Selecting a selection procedure. *Management Science* 53(12), S. 1916–1932.
- Branke, J. und Schmidt, C. (2004): Sequential sampling in noisy environments. In: X. Yao, E. Burke, J. A. Lozano, J. Smith, J. J. Merelo-Guervós, J. A. Bullinaria, J. Rowe, P. Tino, A. Kabán und H.-P. Schwefel (Hrsg.), *Proceedings of the 8th International Conference on Parallel Problem Solving from Nature (PPSN VIII)*, Birmingham. Springer, Berlin, S. 202–211.
- Brannon, E., Thommesen, S. und Marshall, T. (2003): Agent-based modeling of the textile/apparel marketplace. In: L. M. Sztandera und C. Pastore (Hrsg.), *Soft Computing in Textile Sciences*. Physica, Heidelberg, S. 96–123.
- Bremer, J., Andreßen, S., Rapp, B., Sonnenschein, M. und Stadler, M. (2008): A modelling tool for interaction and correlation in demand-side market behaviour. In: D. Möst, W. Fichtner, M. Ragwitz und D. Veit (Hrsg.), *New Methods for Energy Market Modelling – Proceedings of the 1st European Workshop on Energy Market Modelling Using Agent Based Computational Economics*. Universitätsverlag, Karlsruhe, S. 77–91.
- Brenner, T. (2006): Agent learning representation: Advice on modelling economic learning. In: L. Tesfatsion und K. L. Judd (Hrsg.), *Handbook of Computational Economics, Volume 2: Agent-based Computational Economics*. Elsevier, Amsterdam, S. 895–947.
- Brown, D. G., Riolo, R., Robinson, D. T., North, M. und Rand, W. (2005): Spatial process and data models: Toward integration of agent-based models and GIS. *Journal of Geographical Systems* 7(1), S. 25–47.
- Buchanan, M. (2005): Supermodels to the rescue. *Strategy+Business* 38, S. 50–59.
- Buchholz, P. und Thümmel, A. (2005): Enhancing evolutionary algorithms with statistical selection procedures for simulation optimization. In: M. E. Kuhl, N. M. Steiger, F. B. Armstrong und J. A. Joines (Hrsg.), *Proceedings of the Winter Simulation Conference (WSC 2005)*, Orlando. Association for Computing Machinery, New York, S. 842–852.
- Bundesministerium für Wirtschaft und Technologie (BMWi) (2009): Innovationspolitik, Informationsgesellschaft, Telekommunikation – 12. Faktenbericht.
<http://www.bmwi.de/BMWi/Navigation/Service/publikationen,did=303740.html>, abgerufen am 28. Dezember 2010.
- Bundesnetzagentur (2008): Jahresbericht 2008.
<http://www.bundesnetzagentur.de/cae/servlet/contentblob/113828/publicationFile/1113/Jahresbericht08Id15901pdf.pdf>, abgerufen am 28. Dezember 2010.
- Bundesnetzagentur (2009a): Jahresbericht 2009.
<http://www.bundesnetzagentur.de/cae/servlet/contentblob/152206/publicationFile/7883/Jahresbericht2009Id18409pdf.pdf>, abgerufen am 28. Dezember 2010.
- Bundesnetzagentur (2009b): Tätigkeitsbericht Telekommunikation 2008 und 2009.
http://www.bundesnetzagentur.de/cae/servlet/contentblob/143490/publicationFile/1111/TaetigkeitsberichtTK20082009_Id17897pdf.pdf, abgerufen am 28. Dezember 2010.
- Büning, H. und Trenkler, G. (1994): *Nichtparametrische Statistische Methoden*. 2. erweiterte und völlig überarbeitete Auflage, de Gruyter, Berlin.
- Bunn, D. W. und Oliveira, F. S. (2003): Evaluating individual market power in electricity markets via agent-based simulation. *Annals of Operations Research* 121(1), S. 57–77.
- Bunn, D. W. und Oliveira, F. S. (2007): Agent-based analysis of technological diversification and specialization in electricity markets. *European Journal of Operational Research* 181(3), S. 1265–1278.

- Buxton, D., Farr, R. und MacCarthy, B. (2006): The aero-engine value chain under future business environments: Using agent-based simulation to understand dynamic behaviour. In: Proceedings of the International Conference on the Modern Information Technology in the Innovation Processes of the Industrial Enterprises (MITIP 2006), Budapest.
- Calvez, B. und Hutzler, G. (2006): Automatic tuning of agent-based models using genetic algorithms. In: J. Sichman und L. Antunes (Hrsg.), *Multi-Agent-Based Simulation VI*. Springer, Berlin, S. 41–57.
- Capgemini (2007): Mobile Voice in Western Europe. http://www.capgemini.com/insights-and-resources/by-publication/telecom_media_entertainment_insights_journal_volume_4/, abgerufen am 28. Dezember 2010.
- Carley, K. M. (2002): Simulating society: The tension between transparency and veridicality. In: C. Macal und D. Sallach (Hrsg.), *Proceedings of the Conference on Social Agents: Ecology, Exchange and Evolution (Agent 2002)*, Chicago. Argonne National Laboratory, Chicago, S. 103–114.
- Castle, C. J. und Crooks, A. T. (2006): Principles and concepts of agent-based modelling for developing geospatial simulations. Working paper, Centre for Advanced Spatial Analysis, University College London. <http://www.casa.ucl.ac.uk/publications/workingPaperDetail.asp?ID=110>, abgerufen am 28. Dezember 2010.
- Cervenka, R. und Trencansky, I. (2007): *The Agent Modeling Language (AML): A Comprehensive Approach to Modeling Multi-agent Systems*. Birkhäuser, Basel.
- Cha, K. C., Jun, D. B., Wilson, A. R. und Park, Y. S. (2008): Managing and modeling the price reduction effect in mobile telecommunications traffic. *Telecommunications Policy* 32(7), S. 468–479.
- Chang, M.-H. und Harrington, J. E. (2006): Agent-based models of organizations. In: L. Tesfatsion und K. L. Judd (Hrsg.), *Handbook of Computational Economics, Volume 2: Agent-based Computational Economics*. Elsevier, Amsterdam, S. 1273–1337.
- Chen, C.-H., Lin, J., Yücesan, E. und Chick, S. E. (2000): Simulation budget allocation for further enhancing the efficiency of ordinal optimization. *Discrete Event Dynamic Systems* 10(3), S. 251–270.
- Chip Xonio Online (2007): Der Mobilfunk-Report 2007. http://www.chip.de/cxo/b2b_artikel_29222048.html, abgerufen am 28. Dezember 2010.
- Clement, M. und Schollmeyer, T. (2009): Messung und Wirkung von Netzeffekten in der ökonomischen Forschung. *Journal für Betriebswirtschaft* 58(4), S. 173–207.
- Cohendet, P. (1998): Network, interactions between economic agents and irreversibilities: The case of the choice among competing technologies. In: *The Economics of Networks: Interaction and Behaviours*. Springer, New York, S. 93–121.
- Corrocher, N. und Zirulia, L. (2009): Me and you and everyone we know: An empirical analysis of local network effects in mobile communications. *Telecommunications Policy* 33(1-2), S. 68–79.
- Costa, D. und Silver, E. A. (1998): Tabu search when noise is present: An illustration in the context of cause and effect analysis. *Journal of Heuristics* 4(1), S. 5–23.
- Coy, S. P., Golden, B. L., Runger, G. C. und Wasil, E. A. (2001): Using experimental design to find effective parameter settings for heuristics. *Journal of Heuristics* 7(1), S. 77–97.
- da Silva Lima, W. und de Andrade Freitas, E. N. (2006): A multi agent based simulator for brazilian wholesale electricity energy market. In: J. S. Sichman, H. Coelho und S. O. Rezende (Hrsg.), *Advances in Artificial Intelligence – IBERAMIA-SBIA 2006*. Springer, Berlin, S. 68–77.
- Darley, V. und Outkin, A. V. (2007): *A NASDAQ Market Simulation: Insights on a Major Market from the Science of Complex Adaptive Systems*. World Scientific, Singapore.
- Darley, V., Sanders, D. und von Tessen, P. (2004): An agent-based model of a corrugated-box factory: The trade-off between finished goods stock and on-time-in-full delivery. In: H. Coelho und B. Espinasse (Hrsg.), *Proceedings of the Workshop on Agent-based Simulation (ABS 2004)*, Lissabon. SCS Publishing House, Erlangen, S. 113–118.

- Davidsson, P., Holmgren, J., Persson, J. A. und Ramstedt, L. (2008): Multi agent based simulation of transport chains. In: Proceedings of the International Joint Conference on Autonomous Agents and Multiagent Systems (AAMAS 2008), Estoril. International Foundation for Autonomous Agents and Multiagent Systems, Richland, S. 1153–1160.
- Dawid, H. (2006): Agent-based models of innovation and technological change. In: L. Tesfatsion und K. L. Judd (Hrsg.), Handbook of Computational Economics, Volume 2: Agent-based Computational Economics. Elsevier, Amsterdam, S. 1235–1272.
- Deb, K., Pratap, A., Agarwal, S. und Meyarivan, T. (2002): A fast and elitist multiobjective genetic algorithm: NSGA-II. IEEE Transactions on Evolutionary Computation 6(2), S. 182–197.
- Deckert, A. und Klein, R. (2010): Agentenbasierte Simulation zur Analyse und Lösung betriebswirtschaftlicher Entscheidungsprobleme. Journal für Betriebswirtschaft 60(2), S. 89–125.
- Delre, S., Jager, W., Bijmolt, T. und Janssen, M. (2007): Targeting and timing promotional activities: An agent-based model for the takeoff of new products. Journal of Business Research 60(8), S. 826–835.
- Dialog Consult/VATM (2005): Siebte gemeinsame Marktanalyse. http://www.vatm.de/uploads/media/2005-09-26_Marktstudie_2005.pdf, abgerufen am 28. Dezember 2010.
- Dialog Consult/VATM (2009): Elfte gemeinsame Marktanalyse. <http://www.vatm.de/uploads/media/2009-11-04-TK-Marktstudie.pdf>, abgerufen am 28. Dezember 2010.
- Dibble, C. (2006): Computational laboratories for spatial agent-based models. In: L. Tesfatsion und K. L. Judd (Hrsg.), Handbook of Computational Economics, Volume 2: Agent-based Computational Economics. Elsevier, Amsterdam, S. 1511–1548.
- Doganoglu, T. und Grzybowski, L. (2007): Estimating network effects in mobile telephony in Germany. Information Economics and Policy 19(1), S. 65–79.
- Domschke, W. und Drexl, A. (2007): Einführung in Operations Research. 7. überarbeitete Auflage, Springer, Berlin.
- dos Santos, P. M. R. und dos Santos, M. I. R. (2009): Construction of stochastic simulation metamodels based on unreplicated smoothed data. SIMULATION: Transactions of The Society for Modeling and Simulation International 85(6), S. 387–396.
- Eiben, A. und Smith, J. (2007): Introduction to Evolutionary Computing. 2. korrigierte Auflage, Springer, Berlin.
- Entriken, R. und Wan, S. (2005): Agent-based simulation of an automatic mitigation procedure. In: R. Sprague (Hrsg.), Proceedings of the Annual Hawaii International Conference on System Sciences (HICSS 2005), Hawaii. IEEE Computer Society, Los Alamitos.
- Epstein, J. M. (1999): Agent-based computational models and generative social science. Complexity 4(5), S. 41–60.
- Epstein, J. M. und Axtell, R. (1996): Growing Artificial Societies: Social Science from the Bottom up. Brookings Institution Press, Washington.
- Farrell, W. (1998): How Hits Happen: Forecasting Predictability in a Chaotic Marketplace. HarperCollins, New York.
- Ferber, J. (1999): Multi-Agent Systems: An Introduction to Distributed Artificial Intelligence. Addison-Wesley, Boston.
- Focus Verlag/TNS Infratest (2009): Communication Networks 13.0. http://www.medialine.de/media/uploads/projekt/medialine/docs/bestellung_download/forschung/cn/cn13_0_codeplan.pdf, abgerufen am 29. Dezember 2010.
- Franklin, S. und Graesser, A. (1996): Is it an agent, or just a program?: A taxonomy for autonomous agents. In: M. Wooldridge (Hrsg.), Intelligent Agents III: Agent Theories, Architectures, and Languages. Springer, Berlin, S. 21–36.

- Frels, J., Heisler, D., Reggia, J. und Schuetze, H.-J. (2006): Modeling the impact of consumer interactions in technology markets. *Journal of Cellular Automata* 1(2), S. 91–103.
- Frels, J. K., Reggia, J. A. und Heisler, D. (2005): Standard scape: An agent-based model of competition in markets with network externalities. In: MSI Reports Working Paper Series 05-105. Marketing Science Institute, Cambridge.
- Fu, M. C. (2002): Optimization for simulation: Theory vs. practice. *INFORMS Journal on Computing* 14(3), S. 192–215.
- Fu, M. C., Chen, C.-H. und Shi, L. (2008): Some topics for simulation optimization. In: S. J. Mason, R. R. Hill, L. Mönch, O. Rose, T. Jefferson und J. W. Fowler (Hrsg.), *Proceedings of the Winter Simulation Conference (WSC 2008)*, Miami. Association for Computing Machinery, New York, S. 27–38.
- Fu, M. C., Glover, F. W. und April, J. (2005): Simulation optimization: A review, new developments, and applications. In: M. E. Kuhl, N. M. Steiger, F. B. Armstrong und J. A. Joines (Hrsg.), *Proceedings of the Winter Simulation Conference (WSC 2005)*, Orlando. Association for Computing Machinery, New York, S. 83–95.
- Galán, J. M., Izquierdo, L. R., Izquierdo, S. S., Santos, J. I., del Olmo, R., López-Paredes, A. und Edmonds, B. (2009): Errors and artefacts in agent-based modeling. *Journal of Artificial Societies and Social Simulation* 12(1).
- Gambardella, L. M., Rizzoli, A. E. und Zaffalon, M. (1998): Simulation and planning of an intermodal container terminal. *SIMULATION: Transactions of The Society for Modeling and Simulation International* 71(2), S. 107–116.
- Gans, J. S., King, S. P. und Wright, J. (2005): Wireless communications. In: S. K. Majumdar, M. Cave und I. Vogelsang (Hrsg.), *Handbook of Telecommunications Economy*, Volume 2: Technology Evolution and the Internet. Elsevier, Amsterdam, S. 243–288.
- Garcia, R. (2005): Uses of agent-based modeling in innovation/new product development research. *Journal of Product Innovation Management* 22(5), S. 380–398.
- Garifullin, M., Borshchev, A. und Popkov, T. (2007): Using AnyLogic and agent-based approach to model consumer market. In: B. Zupancic, R. Karba und S. Blazic (Hrsg.), *Proceedings of the 6th EUROSIM Congress on Modelling and Simulation (EUROSIM 2007)*, Ljubljana. Eurosim, Universität Ljubljana.
- Gendreau, M. (2003): An introduction to tabu search. In: F. Glover und G. A. Kochenberger (Hrsg.), *Handbook of Metaheuristics*. Kluwer Academic Publishers, Boston, S. 37–54.
- Gerolamo, G. P. B., Franco, J. H. A. und Holanda, G. M. (2004): An agent-based model for evaluating the deployment of telecom services in a competitive market. In: H. Coelho und B. Espinasse (Hrsg.), *Proceedings of the 5th Workshop on Agent-based Simulation (ABS 2004)*, Lissabon. SCS Publishing House, Erlangen, S. 87–92.
- Gerpott, T. J. (1998): Wettbewerbsstrategien im Telekommunikationsmarkt. 3. überarbeitete und erweiterte Auflage, Schäffer-Poeschel, Stuttgart.
- Gerpott, T. J. (2009): Biased choice of a mobile telephony tariff type: Exploring usage boundary perceptions as a cognitive cause in choosing between a use-based or a flat rate plan. *Telematics and Informatics* 26(2), S. 167–179.
- Gibbons, J. D. und Chakraborti, S. (2003): *Nonparametric Statistical Inference*. 4. überarbeitete und erweiterte Auflage, Dekker, New York.
- Gilbert, N. (2007): *Agent-based Models*. Sage Publications, Los Angeles.
- Glover, F., Kelly, J. P. und Laguna, M. (1999): New advances for wedding optimization and simulation. In: P. A. Farrington, H. B. Nemhard, D. T. Sturrock und G. W. Evans (Hrsg.), *Proceedings of the Winter Simulation Conference (WSC 1999)*, Phoenix. Association for Computing Machinery, New York, S. 255–260.
- Glover, F. W. und Laguna, M. (1997): *Tabu Search*. Kluwer Academic Publishers, Boston.
- Gönsch, J., Klein, R. und Steinhardt, C. (2008): Discrete Choice Modelling (Teil I) – Grundlagen. *WiSt – Wirtschaftswissenschaftliches Studium* 37(7), S. 356–362.
- Gönsch, J., Klein, R. und Steinhardt, C. (2009): Dynamic Pricing – State-of-the-Art. *Zeitschrift für Betriebswirtschaft, Ergänzungsheft 3 „Operations Research in der Betriebswirtschaft“*, S. 1–39.

- Goldberg, D. E. (1989): Genetic Algorithms in Search, Optimization, and Machine Learning. Addison-Wesley, Reading.
- Goldsman, D. und Nelson, B. L. (1998): Comparing systems via simulation. In: J. Banks (Hrsg.), Handbook of Simulation: Principles, Methodology, Advances, Applications, and Practice. Wiley, New York, S. 273–306.
- Gosavi, A. (2003): Simulation-Based Optimization. Kluwer Academic Publishers, Boston.
- Gosavi, A., Ozkaya, E. und Kahraman, A. F. (2007): Simulation optimization for revenue management of airlines with cancellations and overbooking. OR Spectrum 29(1), S. 21–38.
- Grajek, M. (2007): Estimating network effects and compatibility in mobile telecommunications. ESMT Research Working Papers 07-001, European School of Management and Technology, Berlin.
<http://ideas.repec.org/p/esm/wpaper/esmt-07-001.html>, abgerufen am 29. Dezember 2010.
- Grimm, V., Revilla, E., Berger, U., Jeltsch, F., Mooij, W. M., Railsback, S. F., Thulke, H.-H., Weiner, J., Wiegand, T. und DeAngelis, D. L. (2005): Pattern-oriented modeling of agent-based complex systems: Lessons from ecology. Science 310(5750), S. 987–991.
- Gruber, H. (2005): The Economics of Mobile Telecommunications. Cambridge University Press, Cambridge.
- Haase, K., Salewski, F. und Skiera, B. (1998): Preisdifferenzierung bei Dienstleistungen am Beispiel von „Call-by-Call“-Tarifen. Zeitschrift für Betriebswirtschaft 68, S. 1053–1072.
- Haddawy, P., Dhananaiyapergse, K., Kaewpitakkun, Y. und Bui, T. (2004): Data-driven agent-based simulation of commercial barter trade. In: N. Zhong (Hrsg.), Proceedings of the International Conference on Intelligent Agent Technology (IAT 2004), Peking. IEEE Computer Society, Los Alamitos, S. 218–224.
- Hamill, L. und Gilbert, N. (2009): Social circles: A simple structure for agent-based social network models. Journal of Artificial Societies and Social Simulation 12(2).
- Han, L. und Neumann, M. (2006): Effect of dimensionality on the nelder–mead simplex method. Optimization Methods and Software 21(1), S. 1–16.
- Hansen, R. (2006): Das Discount Modell – Umbruch im deutschen Mobilfunkmarkt. In: Turbulenzen in der Telekommunikations- und Medienindustrie. Springer, Berlin.
- Harter, G., Plaschka, G. R. und Verma, R. (2007): iChoose – Customer Choice Modeling Applied: A Mobile Phone Case Study. Booz & Company. <http://www.booz.com/media/uploads/iChoose.pdf>, abgerufen am 29. Dezember 2010.
- Haucap, J. (2003): The economics of mobile telephone regulation. Working paper, Universität der Bundeswehr, Hamburg. http://www.hsu-hh.de/fgvwl/index_xlx9yAvk9tT6DYqd.html, abgerufen am 29. Dezember 2010.
- von Hayek, F. A. (1972): Die Theorie Komplexer Phänomene. C.B. Mohr (Paul Siebeck), Tübingen.
- Heath, B., Hill, R. und Ciarallo, F. (2009): A survey of agent-based modeling practices (January 1998 to July 2008). Journal of Artificial Societies and Social Simulation 12(4).
- Henderson, D., Jacobson, S. H. und Johnson, A. W. (2003): The theory and practice of simulated annealing. In: F. Glover und G. A. Kochenberger (Hrsg.), Handbook of Metaheuristics. Kluwer Academic Publishers, Boston, S. 287–320.
- Heppenstall, A., Evans, A. und Birkin, M. (2006): Using hybrid agent-based systems to model spatially-influenced retail markets. Journal of Artificial Societies and Social Simulation 9(3).
- Heppenstall, A. J., Evans, A. J. und Birkin, M. H. (2007): Genetic algorithm optimisation of an agent-based model for simulating a retail market. Environment and Planning B: Planning and Design 34(6), S. 1051–1070.
- Hesse, R. und Rauh, J. (2003): Angebot und Nachfrage im Einzelhandel: Multiagentensysteme zur Simulation von Konsumentenverhalten und der Shopping-Center-Planungen. In: A. Koch und P. Mandl (Hrsg.), Multi-Agenten-Systeme in der Geographie. Klagenfurter Geographische Schriften 23, Institut für Geographie und Regionalforschung der Universität Klagenfurt, S. 65–87.

- Hill, S. D. (2005): Discrete stochastic approximation with application to resource allocation. Johns Hopkins APL Technical Digest 26(1), S. 15–21.
- Hoad, K., Robinson, S. und Davies, R. (2010): Automated selection of the number of replications for a discrete-event simulation. Journal of the Operational Research Society 61(11), S. 1632–1644.
- Hogan, J. E., Lemon, K. N. und Libai, B. (2003): What is the true value of a lost customer? Journal of Service Research 5(3), S. 196–208.
- Holland, J. H. (1995): Hidden Order: How Adaptation Builds Complexity. Addison-Wesley, Reading.
- Homburg, C. und Krohmer, H. (2009): Marketingmanagement: Strategie – Instrumente – Umsetzung – Unternehmensführung. 3. überarbeitete und erweiterte Auflage, Gabler, Wiesbaden.
- Hong, L. J. (2006): Fully sequential indifference-zone selection procedures with variance-dependent sampling. Naval Research Logistics 53(5), S. 464–476.
- Hong, L. J. und Nelson, B. L. (2005): The tradeoff between sampling and switching: New sequential procedures for indifference-zone selection. IIE Transactions 37(7), S. 623–634.
- Hong, L. J. und Nelson, B. L. (2006): Discrete optimization via simulation using COMPASS. Operations Research 54(1), S. 115–129.
- Hong, L. J. und Nelson, B. L. (2007): Selecting the best system when systems are revealed sequentially. IIE Transactions 39(7), S. 723–734.
- Hooker, J. (1995): Testing heuristics: We have it all wrong. Journal of Heuristics 1(1), S. 33–42.
- Inoue, K., Chick, S. E. und Chen, C.-H. (1999): An empirical evaluation of several methods to select the best system. ACM Transactions on Modeling and Computer Simulation 9(4), S. 381–407.
- International Telecommunication Union (ITU) (2009): Information Society Statistical Profiles – Europe v1.1. http://www.itu.int/dms_pub/itu-d/opb/ind/D-IND-RPM.EUR-2009-R1-PDF-E.pdf, abgerufen am 29. Dezember 2010.
- Iyengar, R., Ansari, A. und Gupta, S. (2007): A model of consumer learning for service quality and usage. Journal of Marketing Research 44(4), S. 529–544.
- Jackson, J. (2007): Are US utility standby rates inhibiting diffusion of customer-owned generating systems? Energy Policy 35(3), S. 1896–1908.
- Jackson, M. O. (2008): Social and Economic Networks. Princeton University Press, Princeton.
- Jäger, W. und Janssen, M. (2003): The need for and development of behaviourally realistic agents. In: Multi-Agent-Based Simulation II. Springer, Berlin, S. 36–49.
- Jäger, W., Janssen, M., De Vries, H., De Greef, J. und Vlek, C. (2000): Behaviour in commons dilemmas: Homo economicus and homo psychologicus in an ecological-economic model. Ecological Economics 35(3), S. 357–379.
- Janssen, M. A., Alessa, L. N., Barton, M., Bergin, S. und Lee, A. (2008): Towards a community framework for agent-based modeling. Journal of Artificial Societies and Social Simulation 11(2).
- Janssen, M. A. und Jäger, W. (2002): Stimulating diffusion of green products. Journal of Evolutionary Economics 12(3), S. 283–306.
- Janssen, M. A. und Jäger, W. (2003): Simulating market dynamics: Interactions between consumer psychology and social networks. Artificial Life 9(4), S. 343–356.
- Jaskowski, W. und Kotłowski, W. (2008): On selecting the best individual in noisy environments. In: M. Keijzer (Hrsg.), Proceedings of the 10th Annual Conference on Genetic and Evolutionary Computation (GECCO 2008), Atlanta. Association for Computing Machinery, New York, S. 961–968.
- Jin, Y. und Branke, J. (2005): Evolutionary optimization in uncertain environments – A survey. IEEE Transactions on Evolutionary Computation 9(3), S. 303–317.

- Julka, N., Srinivasan, R. und Karimi, I. (2002): Agent-based supply chain management – 1: Framework and 2: A refinery application. *Computers and Chemical Engineering* 26(12), S. 1755–1781.
- Kahneman, D. und Tversky, A. (Hrsg.) (2000): *Choices, Values, and Frames*. Cambridge University Press, Cambridge.
- Katz, M. L. und Shapiro, C. (1985): Network externalities, competition, and compatibility. *The American Economic Review* 75(3), S. 424–440.
- Kephart, J. O., Hanson, J. E. und Greenwald, A. R. (2000): Dynamic pricing by software agents. *Computer Networks* 32(6), S. 731–752.
- Khoujaa, M., Hadzikadicb, M. und Zaffar, M. A. (2008): An agent based modeling approach for determining optimal price-rebate schemes. *Simulation Modelling Practice and Theory* 16(1), S. 111–126.
- Kiesling, E., Günther, M., Stummer, C. und Wakolbinger, L. M. (2009): An agent-based simulation model for the market diffusion of a second generation biofuel. In: M. D. Rossetti, R. R. Hill, B. Johansson, A. Dunkin und R. G. Ingalls (Hrsg.), *Proceedings of the Winter Simulation Conference (WSC 2009)*, Austin. Association for Computing Machinery, New York, S. 1474–1481.
- Kim, S.-H. und Nelson, B. L. (2006): Selecting the best system. In: S. G. Henderson und B. L. Nelson (Hrsg.), *Handbooks in Operations Research and Management Science, Volume 13: Simulation*. North-Holland, Amsterdam, S. 501–534.
- Kim, W.-S. (2009): Effects of a trust mechanism on complex adaptive supply networks: An agent-based social simulation study. *Journal of Artificial Societies and Social Simulation* 12(3).
- Kleijnen, J. P. und Wan, J. (2007): Optimization of simulated systems: OptQuest and alternatives. *Simulation Modelling Practice and Theory* 15(3), S. 354–362.
- Klein, R. und Scholl, A. (2004): *Planung und Entscheidung: Konzepte, Modelle und Methoden einer Modernen Betriebswirtschaftlichen Entscheidungsanalyse*. Vahlen, München.
- Klein, R. und Steinhardt, C. (2008): *Revenue Management*. Springer, Berlin.
- Kleinman, N. L., Spall, J. C. und Naiman, D. Q. (1999): Simulation-based optimization with stochastic approximation using common random numbers. *Management Science* 45(11), S. 1570–1578.
- Kleywegt, A. J., Shapiro, A. und de Mello, T. H. (2001): The sample average approximation method for stochastic discrete optimization. *SIAM Journal on Optimization* 12(2), S. 479–502.
- Klügl, F. (2000): *Aktivitätsbasierte Verhaltensmodellierung und ihre Unterstützung bei Multiagenten-simulationen*. Dissertation, Universität Würzburg, Fakultät für Mathematik und Informatik.
- Knaak, N., Kruse, S. und Page, B. (2006): An agent-based simulation tool for modelling sustainable logistics systems. In: A. Voinov, A. Jakeman und A. Rizzoli (Hrsg.), *Proceedings of the Summit on Environmental Modelling and Software (iEMSs 2006)*. International Environmental Modelling and Software Society, Burlington.
- Kornhauser, D., Wilensky, U. und Rand, W. (2009): Design guidelines for agent based model visualization. *Journal of Artificial Societies and Social Simulation* 12(1).
- Kreye, C. (2005): *Preisverarbeitung durch Privatkunden im Deutschen Mobilfunkmarkt*. Dr. Kovač, Hamburg.
- Laguna, M. (1997): *Optimization of complex systems with OptQuest*. Working paper, University of Colorado. <http://leeds-faculty.colorado.edu/laguna/publications.htm>, abgerufen am 29. Dezember 2010.
- Laguna, M. und Marti, R. (2002): The OptQuest callable library. In: S. Voß und D. L. Woodruff (Hrsg.), *Optimization Software Class Libraries*. Kluwer Academic Publishers, New York, S. 193–218.
- Laguna, M. und Marti, R. C. (2003): *Scatter Search: Methodology and Implementations in C*. Kluwer Academic Publishers, Boston.
- Lambrecht, A. und Skiera, B. (2006a): Paying too much and being happy about it: Existence, causes, and consequences of tariff-choice biases. *Journal of Marketing Research* 43(2), S. 212–223.

- Lambrech, A. und Skiera, B. (2006b): Ursachen eines Flatrate-Bias – Systematisierung und Messung der Einflussfaktoren. *Schmalenbachs Zeitschrift für Betriebswirtschaftliche Forschung* 58, S. 588–617.
- Lancaster, K. J. (1966): A new approach to consumer theory. *The Journal of Political Economy* 74(2), S. 132–157.
- Law, A. M. (2007): *Simulation Modelling and Analysis*. 4. internationale Auflage, McGraw-Hill Professional, New York.
- Law, A. M. (2008): How to build valid and credible simulation models. In: S. J. Mason, R. R. Hill, L. Mönch, O. Rose, T. Jefferson und J. W. Fowler (Hrsg.), *Proceedings of the Winter Simulation Conference (WSC 2008)*, Miami. Association for Computing Machinery, New York, S. 39–47.
- LeBaron, B. (2006): Agent-based computational finance. In: L. Tesfatsion und K. L. Judd (Hrsg.), *Handbook of Computational Economics, Volume 2: Agent-based Computational Economics*. Elsevier, Amsterdam, S. 1187–1233.
- Lee, L. H., Chew, E. P., Teng, S. und Chen, Y. (2008): Multi-objective simulation-based evolutionary algorithm for an aircraft spare parts allocation problem. *European Journal of Operational Research* 189(2), S. 476–491.
- Lehmann, E. L. (2006): *Nonparametrics: Statistical Methods Based on Ranks*. 1. überarbeitete Auflage, Springer, New York.
- Liehr, M. (2005): *Die Adoption von Kritische-Masse-Systemen: Das Problem der Individuellen Kritischen Masse*. Deutscher Universitätsverlag, Wiesbaden.
- Lim, H. und Kumar, A. (2008): Gender and loyalty in the context of mobile services. *International Journal of Mobile Communications* 6(6), S. 714–728.
- Lin, X. und Lee, L. H. (2006): A new approach to discrete stochastic optimization problems. *European Journal of Operational Research* 172(3), S. 761–782.
- Lonsdale, R. und Parker, R. A. (2007): The application of agent-based simulation modeling to airline passenger booking behavior and revenue management. Präsentation auf der AGIFORS Joint Revenue Management and Cargo Conference 2007, Jeju, Südkorea.
- Luce, R. D. (1959): *Individual Choice Behavior – A Theoretical Analysis*. John Wiley & Sons, New York.
- Luck, M., McBurney, P., Shehory, O. und Willmott, S. (2005): Agent technology: Computing as interaction (a roadmap for agent based computing). AgentLink III. <http://www.agentlink.org/roadmap/al3rm.pdf>, abgerufen am 29. Dezember 2010.
- Lusch, R. F. und Tay, N. S. (2004): Agent-based modeling: Gaining insight into firm and industry performance. In: C. Moorman und D. R. Lehmann (Hrsg.), *Assessing Marketing Strategy Performance*. Marketing Science Institute, Cambridge, S. 213–227.
- Mahajan, V., Muller, E. und Wind, Y. (Hrsg.) (2000): *New-product Diffusion Models*. Kluwer Academic Publishers, Boston.
- Markose, S., Alentorn, A., Millard, S. und Yang, J. (2006): Designing large value payment systems: An agent-based approach. Working paper, University of Essex. <http://privatewww.essex.ac.uk/~scher/Cashlessness/Sept%202006%20IPSSMarkose%20draft.DOC>, abgerufen am 29. Dezember 2010.
- Marks, R. E. (2006): Market design using agent-based models. In: L. Tesfatsion und K. L. Judd (Hrsg.), *Handbook of Computational Economics, Volume 2: Agent-based Computational Economics*. Elsevier, Amsterdam, S. 1339–1380.
- Maryak, J. L. und Chin, D. C. (2004): Global random optimization by simultaneous perturbation stochastic approximation. *Johns Hopkins APL Technical Digest* 25(2), S. 91–100.
- Maryak, J. L. und Chin, D. C. (2008): Global random optimization by simultaneous perturbation stochastic approximation. *IEEE Transactions on Automatic Control* 53(3), S. 780–783.

- McKean, J., Shorter, H., Luck, M., McBurney, P. und Willmott, S. (2008): Technology diffusion: Analysing the diffusion of agent technologies. *Autonomous Agents and Multi-Agent Systems* 17(3), S. 372–396.
- Mele, F. D., Guillén, G., Espuña, A. und Puigjaner, L. (2007): An agent-based approach for supply chain retrofitting under uncertainty. *Computers and Chemical Engineering* 31, S. 722–735.
- Merrill Lynch (2009): Global Wireless Matrix. Bank of America.
- Meyer, M. und Heine, B.-O. (2009): Das Potenzial agentenbasierter Simulationsmodelle. *Die Betriebswirtschaft* 69(4), S. 495–520.
- Meyer, M., Lorscheid, I. und Troitzsch, K. G. (2009): The development of social simulation as reflected in the first ten years of JASSS: A citation and co-citation analysis. *Journal of Artificial Societies and Social Simulation* 12(4).
- Michalewicz, Z. (1996): *Genetic Algorithms + Data Structures = Evolution Programs*. 3. überarbeitete und ergänzte Ausgabe, Springer, Berlin.
- Midgley, D., Marks, R. und Cooper, L. (1997): Breeding competitive strategies. *Management Science* 43(3), S. 257–275.
- Midgley, D., Marks, R. und Kunchamwar, D. (2007): Building and assurance of agent-based models: An example and challenge to the field. *Journal of Business Research* 60(8), S. 884–893.
- Miller, J. H. (1998): Active nonlinear tests (ANTs) of complex simulation models. *Management Science* 44(6), S. 820–830.
- Mizuno, M. und Nishiyama, N. (2003): Interacting TV viewers: A case of empirical agent-based modeling and simulation for business application. *Advances in Complex Systems* 6(3), S. 361–374.
- Mizuta, H. und Steiglitz, K. (2000): Agent-based simulation of dynamic online auctions. In: P. A. Fishwick, K. Kang, J. A. Joines und R. R. Barton (Hrsg.), *Proceedings of the Winter Simulation Conference (WSC 2000)*, Orlando. Association for Computing Machinery, New York, S. 1772–1777.
- Müller, M., Sensfuß, F. und Wietschel, M. (2007): Simulation of current pricing-tendencies in the German electricity market for private consumption. *Energy Policy* 35(8), S. 4283–4294.
- Moore, G. A. (2002): *Crossing the Chasm: Marketing and Selling High-Tech Products to Mainstream Customers*. 2. überarbeitete Ausgabe. HarperCollins, New York.
- Mungamuru, B. und Garcia-Molina, H. (2008): Predictive pricing and revenue sharing. In: *Internet and Network Economics*. Springer, Berlin, S. 53–60.
- Munnukka, J. (2005): Dynamics of price sensitivity among mobile service customers. *Journal of Product and Brand Management* 14(1), S. 65–73.
- Munroe, S., Miller, T., Belecheanu, R. A., Pechoucek, M., McBurney, P. und Luck, M. (2006): Crossing the agent technology chasm: Lessons, experiences and challenges in commercial applications of agents. *The Knowledge Engineering Review* 21(4), S. 345–392.
- Nakayama, M. K. (2008): Statistical analysis of simulation output. In: S. J. Mason, R. R. Hill, L. Mönch, O. Rose, T. Jefferson und J. W. Fowler (Hrsg.), *Proceedings of the Winter Simulation Conference (WSC 2008)*, Miami. Association for Computing Machinery, New York, S. 62–72.
- Narzisi, G., Mysore, V. und Mishra, B. (2006): Multi-objective evolutionary optimization of agent-based models: An application to emergency response planning. In: *Proceedings of the Second IASTED International Conference on Computational Intelligence (CI 2006)*, San Francisco.
- Nelson, B. L., Swann, J., Goldsman, D. und Song, W. (2001): Simple procedures for selecting the best simulated system when the number of alternatives is large. *Operations Research* 49(6), S. 950–963.
- Neumann, K.-H. (1984): *Gebührenpolitik im Telekommunikationsbereich*. Nomos, Baden-Baden.
- Newman, M. E. J. (2003): The structure and function of complex networks. *SIAM Review* 45(2), S. 167–256.
- Ng, I. C. (2008): *The Pricing and Revenue Management of Services: A Strategic Approach*. Routledge, London.

- Nikolai, C. und Madey, G. (2009): Tools of the trade: A survey of various agent based modeling platforms. *Journal of Artificial Societies and Social Simulation* 12(2).
- Ning, Y., Tang, W. und Wang, H. (2005): Hybrid genetic-SPSA algorithm based on random fuzzy simulation for chance-constrained programming. In: *Fuzzy Systems and Knowledge Discovery*. Springer, Berlin.
- Nissen, V. und Propach, J. (1998): On the robustness of population-based versus point-based optimization in the presence of noise. *IEEE Transactions on Evolutionary Computation* 2(3), S. 107–119.
- Norkin, V. I., Pflug, G. C. und Ruszczyński, A. (1998): A branch and bound method for stochastic global optimization. *Mathematical Programming* 83(1-3), S. 425–450.
- North, M., Conzelmann, G., Koritarov, V., Macal, C., Thimmapuram, P. und Veselka, T. (2002): E-laboratories: Agent-based modeling of electricity markets. In: *Proceedings of the American Power Conference 2002*, Chicago.
- North, M. J., Macal, C. M., Aubin, J. S., Thimmapuram, P., Bragen, M., Hahn, J., Karr, J., Brigham, N., Lacy, M. E. und Hampton, D. (2010): Multiscale agent-based consumer market modeling. *Complexity* 15(5), S. 37–47.
- North, M. und Macal, C. (2007): *Managing Business Complexity: Discovering Strategic Solutions with Agent-based Modeling and Simulation*. Oxford University Press, Oxford.
- Oechslein, C. (2004): *Vorgehensmodell mit Integrierter Spezifikations- und Implementierungssprache für Multiagentensimulationen*. Shaker, Aachen.
- Olafsson, S. (1999): Iterative ranking-and-selection for large-scale optimization. In: P. A. Farrington, H. B. Nembhard, D. T. Sturrock und G. W. Evans (Hrsg.), *Proceedings of the Winter Simulation Conference (WSC 1999)*, Phoenix. Association for Computing Machinery, New York, S. 479–485.
- Olafsson, S. (2004): Two-stage nested partitions method for stochastic optimization. *Methodology and Computing in Applied Probability* 6(1), S. 5–27.
- Olafsson, S. (2006): Metaheuristics. In: S. G. Henderson und B. L. Nelson (Hrsg.), *Handbooks in Operations Research and Management Science, Volume 13: Simulation*. North-Holland, Amsterdam, S. 633–654.
- Olafsson, S. und Kim, J. (2002): Simulation optimization. In: E. Yücesan, C.-H. Chena, J. L. Snowdon und J. M. Charnes (Hrsg.), *Proceedings of the Winter Simulation Conference (WSC 2002)*, San Diego. Association for Computing Machinery, New York, S. 79–84.
- OptTek (2008): The OptQuest engine Java and .NET developer's guide.
<http://www.opttek.com/Products/Documentation.html>, abgerufen am 29. Dezember 2010.
- Outkin, A., Flaim, S., Seirp, A. und Gavrilov, J. (2008): FinSim: A framework for modeling financial system interdependencies. In: Y. Shan und A. Yang (Hrsg.), *Applications of Complex Adaptive Systems*. IGI Publishing, Hershey, S. 257–277.
- Parker, D. C., Manson, S. M., Janssen, M. A., Hoffmann, M. J. und Deadman, P. (2003): Multi-agent systems for the simulation of land-use and land-cover change: A review. *Annals of the Association of American Geographers* 93(2), S. 314–337.
- Parunak, H. V. D., Savit, R. und Riolo, R. L. (1998): Agent-based modeling vs. equation-based modeling: A case study and users' guide. In: J. S. Sichman, R. Conte und G. N. Gilbert (Hrsg.), *Proceedings of the First International Workshop on Multi-agent Systems and Agent-based Simulation (MABS 1998)*, Paris. Springer, Berlin, S. 10–25.
- Peterson, G. R. (2006): Species of emergence. *Zygon* 41(3), S. 689–712.
- Petrowski, A. (1996): A clearing procedure as a niching method for genetic algorithms. In: *Proceedings of the IEEE International Conference on Evolutionary Computation (ICEC 1996)*, Nagoya. Institute of Electrical and Electronics Engineers, S. 798–803.
- Pflug, G. (1992): Applicational aspects of stochastic approximation. In: L. Ljung, G. Pflug und H. Walk (Hrsg.), *Stochastic Approximation and Optimization of Random Systems*. Birkhäuser, Basel, S. 53–93.

- Pichitlamken, J., Deslauriers, A., L'Ecuyer, P. und Avramidis, A. N. (2003): Modelling and simulation of a telephone call center. In: S. Chick, P. J. Sanchez, D. Ferrin und D. J. Morrice (Hrsg.), *Proceedings of the Winter Simulation Conference (WSC 2003)*, New Orleans. Association for Computing Machinery, New York, S. 1805–1812.
- Pichitlamken, J. und Nelson, B. L. (2003): A combined procedure for optimization via simulation. *ACM Transactions on Modeling and Computer Simulation* 13(2), S. 155–179.
- Pichitlamken, J., Nelson, B. L. und Hong, L. J. (2006): A sequential procedure for neighborhood selection-of-the-best in optimization via simulation. *European Journal of Operational Research* 173(1), S. 283–298.
- Pidd, M. (2010): Why modelling and model use matter. *Journal of the Operational Research Society* 61(1), S. 14–24.
- Pohl, A. und Schmich, P. (2001): Kundenzufriedenheit und Kundenbindung im Telekommunikationsmarkt. In: E. Oetken (Hrsg.), *Telekommunikation 2001: Das Jahrbuch für Unternehmens-Management*. Schiele & Schön, Berlin, S. 83–108.
- Praca, I., Ramos, C., Valet, Z. und Cordeiro, M. (2005): Intelligent agents for negotiation and game-based decision support in electricity markets. *International Journal of Engineering Intelligent Systems for Electrical Engineering and Communications* 13(2), S. 147–154.
- Rahmandad, H. und Sterman, J. (2008): Heterogeneity and network structure in the dynamics of diffusion: Comparing agent-based and differential equation models. *Management Science* 54(5), S. 998–1014.
- Railsback, S. F., Lytinen, S. L. und Jackson, S. K. (2006): Agent-based simulation platforms: Review and development recommendations. *SIMULATION: Transactions of The Society for Modeling and Simulation International* 82(9), S. 609–623.
- Rajagopalan, H. K., Vergara, F. E., Saydam, C. und Xiaob, J. (2007): Developing effective meta-heuristics for a probabilistic location model via experimental design. *European Journal of Operational Research* 177(1), S. 83–101.
- Rams, W. (2001): *Kundenbindung im Deutschen Mobilfunkmarkt*. Deutscher Universitätsverlag, Wiesbaden.
- Rauh, J., Schenk, T., Fehler, M., Klügl, F. und Puppe, F. (2007): Der simulierte Konsument. In: R. Klein und J. Rauh (Hrsg.), *Analysemethodik und Modellierung in der Geographischen Handelsforschung*, Geographische Handelsforschung 13. LIS Verlag, Passau.
- Richiardi, M., Leombruni, R., Saam, N. und Sonnessa, M. (2006): A common protocol for agent-based social simulation. *Journal of Artificial Societies and Social Simulation* 9(1).
- Rigopoulos, G., Psarras, J. und Askounis, D. (2006): Multiagent based simulation enhancing business decision support systems: An application in electronic payments sector. In: M. H. Hamza (Hrsg.), *Proceedings of the IASTED International Conference on Applied Simulation and Modelling (ASM 2006)*, Rhodes. ACTA Press, Anaheim, S. 418–422.
- Rindsfuser, G. und Klügl, F. (2007): Agent-based pedestrian simulation – A case study of the Bern railway station. *disP – The Planning Review, Netzwerk Stadt und Landschaft NSL* 170. ETH Zürich, S. 9–18.
<http://www.nsl.ethz.ch/index.php/en/content/download/1547/9173/file/>, abgerufen am 29. Dezember 2010.
- Ringle, C. M. (2000): *Strategic Management in the Telecommunications Industry – Competition in the Local Loop*. Books on Demand, Norderstedt.
- Robertson, D. A. (2003): Agent-based models of a banking network as an example of a turbulent environment: The deliberate vs. emergent strategy debate revisited. *Emergence* 5(2), S. 56–71.
- Robertson, D. A. (2005): Agent-based models to manage the complex. In: K. Richardson (Hrsg.), *Managing Organizational Complexity: Philosophy, Theory, and Application*. Information Age, Greenwich, S. 417–430.
- Rogers, E. M. (2003): *Diffusion of Innovations*. 5. Auflage, The Free Press, New York.
- Rogers, E. M. und Kincaid, D. L. (1981): *Communication Networks: Toward a New Paradigm for Research*. The Free Press, New York.

- Rohlf, J. (1974): A theory of interdependent demand for a communications service. *The Bell Journal of Economics and Management Science* 5(1), S. 16–37.
- Rohlf, J. H. (2005): Bandwagon effects in telecommunications. In: S. K. Majumdar, M. Cave und I. Vogelsang (Hrsg.), *Handbook of Telecommunications Economy*, Volume 2: Technology Evolution and the Internet. Elsevier, S. 81–118.
- Roop, J., Fathelrahman, E. und Widergren, S. (2005): Price response can make the grid robust: An agent-based discussion. In: IEEE Power Engineering Society General Meeting 2005, San Francisco. IEEE Operations Center, Piscataway, S. 1100–1104.
- Rosenblueth, A. und Wiener, N. (1945): The role of models in science. *Philosophy of Science* 12(4), S. 316–321.
- Russell, S. und Norvig, P. (2004): *Künstliche Intelligenz*. Pearson, München.
- Samanta, S. K., Woods, J., Ghanbari, M. und Rahman, Z. (2009): Tariff balancing for increased subscription and revenue in a mobile network. *International Journal of Mobile Communications* 7(2), S. 213–231.
- Sargent, R. G. (2007): Verification and validation of simulation models. In: S. G. Henderson, B. Biller, M.-H. Hsieh, J. Shortle, J. D. Tew und R. R. Barton (Hrsg.), *Proceedings of the Winter Simulation Conference (WSC 2007)*, Washington. Association for Computing Machinery, New York, S. 124–137.
- Schade, S., Frey, T. und Mahmoud, N. (2009): Simulation von Diskontpreis-Strategien im GSM Mobilfunkmarkt. *Wirtschaftsinformatik* 51(4), S. 335–346.
- Schelling, T. C. (1978): *Micromotives and Macrobehavior*. Norton, New York.
- Schön-Peterson, C. (2003): *Preismanagement für Telekommunikationsdienstleistungen: Modell- und Methodenorientierter Ansatz zur Entscheidungsunterstützung*. Deutscher Universitätsverlag, Wiesbaden.
- Schnorf, S. (2008): *Diffusion in Sozialen Netzwerken der Mobilkommunikation*. UVK, Konstanz.
- Schutte, S. (2010): Optimization and falsification in empirical agent-based models. *Journal of Artificial Societies and Social Simulation* 13(1).
- Schwoon, M. (2006): Simulating the adoption of fuel cell vehicles. *Journal of Evolutionary Economics* 16(4), S. 435–472.
- Scott, J. (2000): *Social Network Analysis*. 2. Auflage, Sage Publications, London.
- Seibel, F. und Kellam, L. (2003): The virtual world of agent-based modeling: Procter&Gamble's dynamic supply chain. *Perspectives on Business Innovation* 9, S. 22–27. http://www.leader-values.com/Downloads/CBI/Journal_Issue_9.pdf, abgerufen am 29. Dezember 2010.
- Seibel, F. und Thomas, C. (1999): Manifest destiny: Adaptive cargo routing at Southwest Airlines. *Perspectives on Business Innovation* 4, S. 27–33. http://www.leader-values.com/Downloads/CBI/Journal_Issue_4.pdf, abgerufen am 29. Dezember 2010.
- Sensfuß, F. (2008): *Assessment of the Impact of Renewable Electricity Generation on the German Electricity Sector – An Agent-based Simulation Approach*. VDI, Düsseldorf.
- Sensfuß, F., Genoese, M. und Ragwitz, M. (2008): Analysis of the impact of renewable electricity generation on CO₂ emissions and power plant operation in Germany. In: U. Bachhiesl und C. Huber (Hrsg.), 10. Symposium Energieinnovation Energiewende (EnInnov 2008), Graz. Technische Universität Graz.
- Shapiro, A. (2003): Monte carlo sampling methods. In: A. Ruszczyński und A. Shapiro (Hrsg.), *Handbooks in Operations Research and Management Science*, Volume 10: Stochastic Programming. North-Holland, Amsterdam, S. 353–425.
- Shi, D. und Brooks, R. J. (2007): The range of predictions for calibrated agent-based simulation models. In: S. G. Henderson, B. Biller, M.-H. Hsieh, J. Shortle, J. D. Tew und R. R. Barton (Hrsg.), *Proceedings of the Winter Simulation Conference (WSC 2007)*, Washington. Association for Computing Machinery, New York, S. 1198–1206.
- Shi, L. und Chen, C.-H. (2000): New algorithm for stochastic discrete resource allocation optimization. *Discrete Event Dynamic Systems: Theory and Applications* 10(3), S. 271–294.

- Shi, L. und Olafsson, S. (2000): Nested partitions method for stochastic optimization. *Methodology and Computing in Applied Probability* 2(3), S. 271–291.
- Shrestha, S. und Mayer, R. H. (2008): Modeling of air traffic arrival operations through agent-based simulation. In: S. J. Mason, R. R. Hill, L. Mönch, O. Rose, T. Jefferson und J. W. Fowler (Hrsg.), *Proceedings of the Winter Simulation Conference (WSC 2008)*, Miami. Association for Computing Machinery, New York, S. 2673–2681.
- Siebers, P.-O., Aickelin, U., Celia, H. und Clegg, C. W. (2010): Simulating customer experience and word-of-mouth in retail – A case study. *SIMULATION: Transactions of The Society for Modeling and Simulation International* 86(1), S. 5–30.
- Simon, H. A. (1996): *The Sciences of the Artificial*. MIT Press, Cambridge.
- Simon, H. und Fassnacht, M. (2006): *Preismanagement*. 3. vollständig überarbeitete und erweiterte Auflage, Gabler, Wiesbaden.
- Sinha, A. und Goldberg, D. E. (2003): A survey of hybrid genetic and evolutionary algorithms. Illinois Genetic Algorithms Laboratory (IlliGAL) Report 2003004. University of Illinois at Urbana-Champaign, Department of General Engineering. <http://illigal.org/2003/04/04/a-survey-of-hybrid-genetic-and-evolutionary-algorithms/>, abgerufen am 29. Dezember 2010.
- Skiera, B. (1998): TACO: Eine neue Möglichkeit zum Vergleich von Mobilfunktarifen. *Schmalenbachs Zeitschrift für Betriebswirtschaftliche Forschung* 50(11), S. 1029–1047.
- Skiera, B. (1999): *Mengenbezogene Preisdifferenzierung bei Dienstleistungen*. Deutscher Universitätsverlag, Wiesbaden.
- Solon (2005): Mobilfunk Deutschland 2010. <http://www.solonstrategy.com/publikationen/>, abgerufen am 29. Dezember 2010.
- Spall, J. C. (1998a): Implementation of the simultaneous perturbation algorithm for stochastic optimization. *IEEE Transactions on Aerospace and Electronic Systems* 34(3), S. 817–823.
- Spall, J. C. (1998b): An overview of the simultaneous perturbation method for efficient optimization. *Johns Hopkins APL Technical Digest* 19(4), S. 482–492.
- Spall, J. C. (2003): *Introduction to Stochastic Search and Optimization: Estimation, Simulation, and Control*. Wiley-Interscience, Hoboken.
- Spall, J. C. (2004): Stochastic optimization. In: J. E. Gentle, W. Härdle und Y. Mori (Hrsg.), *Handbook of Computational Statistics*. Springer, New York, S. 169–197.
- Spall, J. C., Hill, S. D. und Stark, D. R. (2006): Theoretical framework for comparing several stochastic optimization approaches. In: G. Calafiore und F. Dabbene (Hrsg.), *Probabilistic and Randomized Methods for Design under Uncertainty*. Springer, London, S. 99–117.
- Späth, G.-M. (1995): *Preisstrategien für Innovative Telekommunikationsdienste: Entwicklung eines DV-gestützten Simulationsansatzes*. Gabler, Wiesbaden.
- Stagge, P. (1998): Averaging efficiently in the presence of noise. In: A. E. Eiben, T. Bäck, M. Schoenauer und H.-P. Schwefel (Hrsg.), *Parallel Problem Solving from Nature – PPSN V*. Springer, Berlin, S. 188–200.
- Stahmer, B. P. (2006): *SimMarket: Simulation des Abverkaufsverhaltens von Artikeln des Einzelhandels mit probabilistischen Agenten*. Dissertation, Universität des Saarlandes, Naturwissenschaftlich-Technische Fakultät.
- Sterman, J. D. (2000): *Business Dynamics: Systems Thinking and Modeling for a Complex World*. McGraw-Hill, London.
- Stern (2006): *TrendProfile Mobilfunk 2/06*. http://www.gujmedia.de/_content/20/10/201058/TP_Mobilfunk_2_06.pdf, abgerufen am 29. Dezember 2010.
- Stingel, S. (2008): *Tarifwahlverhalten im Business-to-Business-Bereich: Empirisch Gestützte Analyse am Beispiel Mobilfunktarife*. Gabler, Wiesbaden.

- Stranjak, A., Dutta, P. S., Ebdem, M., Rogers, A. und Vytelingum, P. (2008): A multi-agent simulation system for prediction and scheduling of aero engine overhaul. In: *Proceedings of the International Joint Conference on Autonomous Agents and Multiagent Systems (AAMAS 2008)*, Estoril. International Foundation for Autonomous Agents and Multiagent Systems, Richland, S. 81–88.
- Stroud, P. D. (2001): Kalman-extended genetic algorithm for search in nonstationary environments with noisy fitness evaluations. *IEEE Transactions on Evolutionary Computation* 5(1), S. 66–77.
- Strube, J., Schade, S., Schmidt, P. und Buxmann, P. (2007): Simulating indirect network effects in the video game market. In: *Proceedings of the 40th Annual Hawaii International Conference on System Sciences (HICSS 2007)*, Hawaii. IEEE Computer Society, Washington.
- Suematsu, Y. I., Takadama, K., Nawa, N. E., Shimohara, K. und Katai, O. (2003): Analyzing the agent-based model and its implications. *Advances in Complex Systems* 6(3), S. 331–348.
- Sueyoshia, T. und Tadiparthi, G. R. (2008): An agent-based decision support system for wholesale electricity market. *Decision Support Systems* 44(2), S. 425–446.
- Sun, J. und Tesfatsion, L. (2007): Dynamic testing of wholesale power market designs: An open-source agent-based framework. *Computational Economics* 30(3), S. 291–327.
- Sundararajan, A. (2007): Local network effects and complex network structure. *The BE Journal of Theoretical Economics* 7(1) Contributions, Art. 46.
- Swaminathan, J. M., Smith, S. F. und Sadeh, N. M. (1998): Modeling supply chain dynamics: A multiagent approach. *Decision Sciences* 29(3), S. 607–632.
- Swisher, J. R., Hyden, P. D., Jacobson, S. H. und Schruben, L. W. (2004): A survey of recent advances in discrete input parameter discrete-event simulation optimization. *IIE Transactions* 36(6), S. 591–600.
- Swisher, J. R., Jacobson, S. H. und Yucsan, E. (2003): Discrete-event simulation optimization using ranking, selection, and multiple comparison procedures. *ACM Transactions on Modeling and Computer Simulation* 13(2), S. 134–154.
- Tacke, G. (1989): *Nichtlineare Preisbildung*. Gabler, Wiesbaden.
- Takahashi, I. und Okada, I. (2003): Monetary policy and banks' loan supply rules to harness asset bubbles and crashes. In: D. Hales, B. Edmonds, E. Norling und J. Rouchier (Hrsg.), *Multi-agent-based Simulation III*. Springer, Berlin, S. 89–105.
- Tekin, E. und Sabuncuoglu, I. (2004): Simulation optimization: A comprehensive review on theory and applications. *IIE Transactions* 36(11), S. 1067–1081.
- TeleGeography (2010): *Country Profile – Germany*. PriMetrica, Washington.
- Terano, T. (2007): Exploring the vast parameter space of multi-agent based simulation. In: L. Antunes und K. Takadama (Hrsg.), *Multi-agent-based Simulation VII*. Springer, Berlin, S. 1–14.
- Tesfatsion, L. (2002): Agent-based computational economics: Growing economies from the bottom up. *Artificial Life* 8(1), S. 55–82.
- Tesfatsion, L. (2006): Agent-based computational economics: A constructive approach to economic theory. In: L. Tesfatsion und K. L. Judd (Hrsg.), *Handbook of Computational Economics, Volume 2: Agent-based Computational Economics*. Elsevier, Amsterdam, S. 831–880.
- Thengvall, B. und Glover, F. (2009): A framework for the optimization and analysis of agent-based models. In: M. D. Rossetti, R. R. Hill, B. Johansson, A. Dunkin und R. G. Ingalls (Hrsg.), *Proceedings of the Winter Simulation Conference (WSC 2009)*, Austin. Association for Computing Machinery, New York, S. 1737–1744.
- TNS Infratest/E-Plus Gruppe (2010): *Mobilfunknutzung und Nutzungsabsichten*. http://www.eplus-gruppe.de/download/filedownload.asp?folder=presse_studie&file=Mobilfunknutzung2010_Studie_Infratest_EPlus.pdf, abgerufen am 29. Dezember 2010.

- Trosset, M. W. (2000): On the use of direct search methods for stochastic optimization. Working paper, College of William & Mary, Williamsburg, USA. <http://www.caam.rice.edu/caam/trs/2000/TR00-20.ps>, abgerufen am 29. Dezember 2010.
- Unland, R., Klusch, M. und Calisti, M. (Hrsg.) (2005): Software Agent-based Applications, Platforms and Development Kits. Birkhäuser, Basel.
- Valente, T. W. (1995): Network Models of the Diffusion of Innovations. Hampton Press, Cresskill.
- Veit, D. (2006): Markets for Non-storable Goods – Analysis Under Application of Agent-based Simulations. Habilitation, Universität Karlsruhe, Fakultät für Wirtschaftswissenschaften.
- Venables, M. und Bilge, U. (1998): Complex adaptive modeling at J Sainsbury: The SimStore supermarket supply chain experiment. Report, London School of Economics, Strategy & Complexity Seminar. http://www.psych.lse.ac.uk/complexity/events/1995_1999/1998/seminar_30march98.html, abgerufen am 29. Dezember 2010.
- Vrba, P. und Marik, V. (2005): Simulation in agent-based manufacturing control systems. In: Proceedings of the IEEE International Conference on Systems Man and Cybernetics 2005, Waikoloa. IEEE Operations Center, Piscataway.
- Watts, D. J. (2003): Six Degrees: The Science of a Connected Age. W.W. Norton, New York.
- Watts, D. J. und Strogatz, S. H. (1998): Collective dynamics of ‘small-world’ networks. *Nature* 393, S. 440–442.
- Weidlich, A. (2008): Engineering Interrelated Electricity Markets: An Agent-based Computational Approach. Physica-Verlag, Heidelberg.
- Weidlich, A. und Veit, D. (2008a): A critical survey of agent-based wholesale electricity market models. *Energy Economics* 30(4), S. 1728–1759.
- Weidlich, A. und Veit, D. (2008b): PowerACE: Ein agentenbasiertes Tool zur Simulation von Strom- und Emissionsmärkten. In: M. Bichler, T. Hess, H. Krcmar, U. Lechner, F. Matthes, A. Picot, B. Speitkamp und P. Wolf (Hrsg.), Tagungsband der Multikonferenz Wirtschaftsinformatik (MKWI 2008), München. GITO-Verlag, Berlin, S. 875–886.
- Weiss, G. (Hrsg.) (1999): Multiagent Systems: A Modern Approach to Distributed Artificial Intelligence. MIT Press, Cambridge.
- Wendt, O., v. Westarp, F. und König, W. (2000): Diffusionsprozesse in Märkten für Netzeffektgüter: Determinanten, Simulationsmodell und Marktklassifikation. *Wirtschaftsinformatik* 42(5), S. 422–433.
- Weyns, D., Omicini, A. und Odell, J. (2007): Environment as a first class abstraction in multiagent systems. *Autonomous Agents and Multi-Agent Systems* 14(1), S. 5–30.
- Wiedemer, V. (2007): Standardisierung und Koexistenz in Netzeffektmärkten. Josef Eul Verlag, Lohmar.
- Wilensky, U. und Rand, W. (2007): Making models match: Replicating an agent-based model. *Journal of Artificial Societies and Social Simulation* 10(4).
- Wilhite, A. (2006): Economic activity on fixed networks. In: L. Tesfatsion und K. L. Judd (Hrsg.), *Handbook of Computational Economics, Volume 2: Agent-based Computational Economics*. Elsevier, Amsterdam, S. 1013–1045.
- Wolpert, D. H. und Macready, W. G. (1997): No free lunch theorems for optimization. *IEEE Transactions on Evolutionary Computation* 1(1), S. 67–82.
- Wooldridge, M. (2009): An Introduction to Multiagent Systems. 2. Auflage, Wiley, Chichester.
- Wooldridge, M. und Jennings, N. R. (1995): Intelligent agents: Theory and practice. *The Knowledge Engineering Review* 10(2), S. 115–152.
- Xiang, X., Kennedy, R., Madey, G. und Cabaniss, S. (2005): Verification and validation of agent-based scientific simulation models. In: Proceedings of the Agent-directed Simulation Conference (ADS 2005), San Diego. S. 47–55.

Xu, J., Nelson, B. L. und Hong, J. L. (2010): Industrial strength COMPASS: A comprehensive algorithm and software for optimization via simulation. *ACM Transactions on Modeling and Computer Simulation* 20(1).

Zhang, T. und Zhang, D. (2007): Agent-based simulation of consumer purchase decision-making and the decoy effect. *Journal of Business Research* 60(8), S. 912–922.